Paulo Roberto Caixeta Júnior

Otimização Multidisciplinar em Projeto de Asas Flexíveis Utilizando Metamodelos

Tese apresentada à Escola de Engenharia de
São Carlos, da Universidade de São Paulo,
como parte dos requisitos para a obtenção do
título de Doutor em Engenharia Mecânica.
Área de concentração: Aeronaves

VERSÃO CORRIGIDA. A VERSÃO ORIGINAL
ESTÁ DISPONÍVEL JUNTO AO DEPARTA-
MENTO DE ENGENHARIA MECÂNICA DA
EESC-USP.

Orientador: Prof. Assoc. Flávio Donizeti Marques

São Carlos

2011

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

C138o Caixeta Júnior, Paulo Roberto
Otimização multidisciplinar em projeto de asas flexíveis utilizando metamodelos / Paulo Roberto Caixeta Júnior ; orientador Flávio Donizeti Marques. -- São Carlos, 2011.

Tese (Doutorado-Programa de Pós-Graduação em Engenharia Mecânica e Área de Concentração em Aeronaves) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2011.

1. Redes neurais. 2. Otimização multidisciplinar em Projeto(MDO). 3. Metamodelagem. 4. Funções de base radial. 5. Aeroelasticidade. 6. Flutter. 7. Algoritmos genéticos multi-objetivo. 8. Método dos elementos finitos. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **PAULO ROBERTO CAIXETA JUNIOR**

Título da tese: **Otimização multidisciplinar em projeto de asas flexíveis utilizando metamodelos.**

Data da defesa: 11/08/2011:

Comissão Julgadora:

Flávio Donizeti Marques
Prof. Associado **Flávio Donizeti Marques (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Maíra M. da Silva
Prof.^a Dr.^a **Maíra Martins da Silva**
(Escola de Engenharia de São Carlos/EESC)

Paulo Seleghim Júnior
Prof. Titular **Paulo Seleghim Júnior**
(Escola de Engenharia de São Carlos/EESC)

Emílio Carlos Nelli Silva
Prof. Titular **Emílio Carlos Nelli Silva**
(Escola Politécnica/USP)

Roberto Gil Annes da Silva
Prof. Dr. **Roberto Gil Annes da Silva**
(Instituto Tecnológico de Aeronáutica/ITA)

Resultado:

APROVADO

APROVADO

Aprovado

APROVADO

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Marcelo Areias Trindade**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo Cesar Lima Segantine**

“À minha amada esposa Michele e ao meu filho Felipe”

Agradecimentos

Agradeço a Deus, por todas a Suas bênçãos e por guiar a minha vida.

À minha esposa, Michele, pela paciência, apoio, companhia e acima de tudo, pelo seu amor.

Ao meu amado filho, Felipe, pela alegria de todos os dias. Também por algumas noites sem dormir, que me fizeram trabalhar de madrugada...

Aos meus pais, Paulo e Eloide, pela educação e todo apoio que me deram e pelo lar cheio de amor em que cresci.

À minha querida irmã, Luciana, pela amizade, companheirismo e todo estímulo.

Ao meu orientador, Prof. Assoc. Flávio D. Marques, pelo ótimo trabalho em me mostrar os caminhos da vida acadêmica.

Ao Prof. Dr. Álvaro Abdalla e ao Prof. Carlos De Marqui Jr., pelos trabalhos em conjunto e pela constante disposição para me ajudar.

Aos demais professores e funcionários do Departamento de Engenharia Aeronáutica, pelo suporte durante toda minha vida na USP.

Aos colegas da pós: “Rush” (Marcelo Ribeiro), “R1” e “R2” (Ricardos Angélico e de Medeiros), Rui Vasconcellos, Wander, Douglas, Dawson, Mauricio, Fábio, “Smile” (Marcos), Elmer, Vagner, Daniel, Luciano e todos os outros que eu esqueci os nomes, por tornarem a vida na USP mais agradável e divertida, também pelas conversas sobre os diversos temas de pesquisa que cada um desenvolve.

A todos que direta ou indiretamente contribuíram com a produção deste trabalho, meus sinceros agradecimentos.

Finalmente, agradeço ao CNPq pelo suporte financeiro que garantiu o desenvolvimento deste doutorado.

Conteúdo

Resumo	xiii
Abstract	xv
Lista de Símbolos	1
Acrônimos	5
1 Introdução	7
1.1 Otimização Multidisciplinar em Projeto	7
1.1.1 MDO com Restrição Aeroelástica	12
1.1.2 MDO com Utilização de Metamodelos	16
1.1.3 MDO Baseado em Algoritmos Genéticos	19
1.2 Objetivos	24
1.3 Estrutura da Tese	25
2 Previsão de Flutter e Metamodelagem	27
2.1 Solução Aeroelástica	27
2.1.1 Modelo Dinâmico-Estrutural	28
2.1.2 Modelo Aerodinâmico	34

2.1.3	Método de Solução de <i>Flutter</i>	37
2.2	Metamodelos	41
2.2.1	Metamodelagem via Rede Neural	44
2.2.2	Metamodelagem via Interpolação por Funções de Base Radial	46
2.2.3	Metamodelagem via Rede Neural por Funções de Base Radial	49
3	Organização do Processo de MDO	53
3.1	Otimização por Algoritmo Genético	53
3.1.1	Operadores dos Algoritmos Genéticos	55
3.1.2	Funcionamento de um AG Básico	58
3.2	Otimização Multiobjetivo	59
4	Resultados	63
4.1	Banco de Dados	63
4.2	Escolha do Metamodelo para o MDO	66
4.2.1	Metamodelo RN	67
4.2.2	Metamodelo Interpolação por RBF	68
4.2.3	Metamodelo RN por RBF	69
4.2.4	Metamodelo Escolhido	71
4.3	Desempenho do AG	73
4.4	Estudos de Caso	88
5	Conclusões	105
	Sugestões para Trabalhos Futuros	107

Resumo

Caixeta Jr., P.R. (2011). *Otimização Multidisciplinar em Projeto de Asas Flexíveis Utilizando Metamodelos*. São Carlos, 2011. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

A Otimização Multidisciplinar em Projeto (em inglês, *Multidisciplinary Design Optimization* – MDO) é uma ferramenta de projeto importante e versátil e seu uso está se expandindo em diversos campos da engenharia. O foco desta metodologia é unir disciplinas envolvidas no projeto para que trabalhem suas variáveis concomitantemente em um ambiente de otimização, para obter soluções melhores. É possível utilizar MDO em qualquer fase do projeto, seja a fase conceitual, preliminar ou detalhada, desde que os modelos numéricos sejam ajustados às necessidades de cada uma delas. Este trabalho descreve o desenvolvimento de um código de MDO para o projeto conceitual de asas flexíveis de aeronaves, com restrição quanto ao fenômeno denominado *flutter*. Como uma ferramenta para o projetista na fase conceitual, os modelos numéricos devem ser razoavelmente precisos e rápidos. O intuito deste estudo é analisar o uso de metamodelos para a previsão do *flutter* de asas de aeronaves no código de MDO, ao invés de um modelo convencional, o que pode alterar significativamente o custo computacional da otimização. Para este fim são avaliados três técnicas diferentes de metamodelagem, que foram escolhidas por representarem duas classes básicas de metamodelos, a classe de métodos de interpolação e a de métodos de aproximação. Para representá-las foram escolhidos o método de interpolação por funções de base radial e o método de redes neurais artificiais, respectivamente. O terceiro método, que é considerado um método híbrido dos dois anteriores, é chamado de redes neurais por funções de bases radiais e é uma tentativa de acoplar as características de ambos em um único metamodelo. Os metamodelos são preparados utilizando um código para solução aeroelástica baseado no método dos elementos finitos acoplado com um modelo aerodinâmico linear de faixas. São apresentados resultados de desempenho dos três metamodelos, de onde se pode notar que a rede neural artificial é a mais adequada para previsão de *flutter*. O processo de MDO é realizado com o uso de um algoritmo genético multi-objetivo baseado em não-dominância, cujos objetivos são a maximização da velocidade crítica de *flutter* e a minimização da massa estrutural. Dois estudos de caso são apresentados para avaliar o desempenho do código de MDO, revelando que o processo global de otimização realiza de fato a busca pela fronteira de Pareto.

Palavras chave: Otimização Multidisciplinar em Projeto (MDO), Metamodelagem, Redes Neurais, Funções de Base Radial, Aeroelasticidade, *Flutter*, Método dos Elementos Finitos, Algoritmos Genéticos Multi-Objetivo.

Abstract

Caixeta Jr., P.R. (2011). *Multidisciplinary Design Optimization of Flexible Wings Using Metamodels*. São Carlos, 2011. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

The Multidisciplinary Design Optimization, MDO, is an important and versatile design tool and its use is spreading out in several fields of engineering. The focus of this methodology is to put together disciplines involved with the design to work all their variables concomitantly, at an optimization environment to obtain better solutions. It is possible to use MDO in any stage of the design process, that is in the conceptual, preliminary or detailed design, as long as the numerical models are fitted to the needs of each of these stages. This work describes the development of a MDO code for the conceptual design of flexible aircraft wings, with restrictions regarding the phenomenon called flutter. As a tool for the designer at the conceptual stage, the numerical models must be fairly accurate and fast. The aim of this study is to analyze the use of metamodels for the flutter prediction of aircraft wings in the MDO code, instead of a conventional model itself, what may affect significantly the computational cost of the optimization. For this purpose, three different metamodeling techniques have been evaluated, representing two basic metamodel classes, that are, the interpolation and the approximation class. These classes are represented by the radial basis function interpolation method and the artificial neural networks method, respectively. The third method, which is considered as a hybrid of the other two, is called radial basis function neural networks and is an attempt of coupling the features of both in single code. Metamodels are prepared using an aeroelastic code based on finite element model coupled with linear aerodynamics. Results of the three metamodels performance are presented, from where one can note that the artificial neural network is best suited for flutter prediction. The MDO process is achieved using a non-dominance based multi-objective genetic algorithm, whose objectives are the maximization of critical flutter speed and minimization of structural mass. Two case studies are presented to evaluate the performance of the MDO code, revealing that overall optimization process actually performs the search for the Pareto frontier.

Keywords: Multidisciplinary Design Optimization (MDO), Metamodeling, Neural Networks, Radial Basis Functions, Aeroelasticity, Flutter, Finite Element Method, Multi-Objective Genetic Algorithms.

Lista de Símbolos

A	Área da seção transversal do elemento
$[A_{k*}^{aux}]$	Matriz auxiliar para montagem das matrizes globais
$[A]$	Matriz de coeficientes de influência aerodinâmicos geral
A_I	Área da seção transversal calculada pela eq. de I
A_J	Área da seção transversal calculada pela eq. de J
a	Vetor de coeficientes dos polinômios de interpolação por RBF
a_c	Coefficiente aleatório do cruzamento no AG
B	Envergadura da asa
b	Semi-corda da faixa
b_r	Largura da seção transversal
c	Corda da faixa
$\{C_a\}$	Vetor de carregamento aerodinâmico
C_{L_α}	Derivada do coeficiente de sustentação por ângulo de ataque
d_{ij}	Distância entre soluções na fronteira de não-dominância
E	Módulo de elasticidade do material
EI	Rigidez flexional
EI_1	Valor da rigidez flexional na seção mais próxima à raiz da asa
EI_8	Valor da rigidez flexional na seção mais próxima à ponta da asa
F_1, F_2	Filhos no AG
$F_j^{(q)}$	Valor da função de aptidão atribuído
$F_j'^{(q)}$	Valor da função de aptidão compartilhado
F_{min}	Valor mínimo da função de aptidão

f	Fator de forma da estrutura
$f(x)$	Funções interpoladas por RBF
$\mathbf{f}$	Vetor de funções interpoladas por RBF
G	Módulo de elasticidade transversal do material
GJ	Rigidez torcional
GJ_1	Valor da rigidez torcional na seção mais próxima à raiz da asa
GJ_8	Valor da rigidez torcional na seção mais próxima à ponta da asa
g_l	Número de graus de liberdade de cada nó do elemento finito
g	Amortecimento artificial
h	Deslocamento vertical da faixa
h_r	Altura da seção transversal
I	Momento polar de inércia
J	Momento polar de inércia à torção
k^*	Índice do passo na montagem das matrizes globais
$[K_e]$	Matriz de rigidez do elemento
$[K_g]$	Matriz de rigidez global
$[K_{gen}]$	Matriz de rigidez generalizada
l_e	Comprimento do elemento
L_f	Força de sustentação da faixa
M	Massa total da estrutura
$[M_e]$	Matriz de massa do elemento
M_f	Momento de arfagem da faixa
$[M_g]$	Matriz de massa global
$[M_{gen}]$	Matriz de massa generalizada
$[M_O]$	Matriz de massa acumulada até o passo $(k^* - 1)$
N	Número de elementos finitos
N_f	Número de soluções na fronteira de não-dominância
N_p	Número de indivíduos na população

n	Número de objetivos da otimização
nc_q	Contador de nicho para cálculo de aptidão
o_j	Saída do j -ésimo neurônio
P	População no bloco de avaliação por não-dominância
P_j	Fronteiras de não dominância
P_{1c}, P_{2c}	País no AG
$\mathbf{P}$	Matriz de combinações de polinômios da interpolação por RBF
p	Variável de Laplace adimensional
$p(x)$	Polinômio da interpolação por RBF
$[Q_{tot}(k)]$	Matriz de coeficientes de influência aerodinâmicos da asa
$[Q_l(k)]$	Matriz de coeficientes de influência aerodinâmicos da l -ésima faixa
q	Número de nichos igualmente espaçados no espaço de busca
q_∞	Pressão dinâmica do escoamento não perturbado
r	Raio na RBF
S	Área em planta da asa
S_f	Área superficial da faixa
S_h	Função de compartilhamento
s	Variável de Laplace
$s(x)$	Função de interpolação por RBF
$\{u(t)\}$	Vetor de posições
$u_1, \dots, u_{12}$	Graus de liberdade dos elementos finitos
$\{U\}$	Vetor de modos naturais
$[U]$	Matriz modal
$\{\bar{u}(s)\}$	Vetor de posições no domínio da variável de Laplace
V	Velocidade do escoamento não perturbado
V_{crit}	Velocidade crítica de <i>flutter</i>
w_{ij}	Peso da i -ésima entrada no j -ésimo neurônio ou da interp. por RBF
$\mathbf{w}$	Vetor de pesos da interpolação por RBF

x	Coordenada de deslocamento longitudinal (direção da fuselagem)
x_i	i -ésima entrada da rede
y	Coordenada de deslocamento lateral (direção da envergadura)
z	Coordenada de deslocamento vertical da faixa
α	Ângulo de ataque da faixa
α_a	Expoente da função de compartilhamento
β	Constante de espalhamento da RBF
β_f	Ângulo de fase
ϵ	Constante para cálculo de aptidão
Φ	Matriz de interpolação por RBF
$\phi(r)$	Função de base radial (RBF)
ϕ_h	Ângulo de torção nas funções de forma do modelo estrutural
$\varphi ()$	função de ativação
γ	Taxa de decaimento (amortecimento aerodinâmico)
$\eta(t)$	Vetor de posições no espaço modal
λ	Razão de afilamento da asa
λ_k	Auto-valor complexo da solução do <i>flutter</i> pelo método K
Λ	Ângulo de enflechamento do bordo de ataque da asa
ω	Frequência de oscilação harmônica
ω_f	Frequência de <i>flutter</i>
ω_n	Frequências naturais
ρ	Densidade do ar
ρ_n	Número de fronteiras de não-dominância
ρ_e	Densidade do material do elemento
σ_{share}	Parâmetro de compartilhamento
$\psi_1, \dots, \psi_6$	Polinômios de Hermite
θ_j	valor do <i>bias</i> para o j -ésimo neurônio
$()'$	$\frac{d()}{dy}$

$()''$	$\frac{d^2()}{dy^2}$
(l)	Limite inferior de cada objetivo da otimização
(u)	Limite superior de cada objetivo da otimização

Acrônimos

AG	Algoritmo genético
CS1	Primeiro caso para estudo
CS2	Segundo caso para estudo
DOE	Planejamento de experimentos (sigla em inglês)
HALE	Aeronaves de vôo de grande altitude e grande autonomia (sigla em inglês)
LHS	Amostragem por hipercubo latino (sigla em inglês)
MDO	Otimização multidisciplinar em projeto (sigla em inglês)
MEF	Método dos elementos finitos
NSGA	Algoritmo genético com seleção por não-dominância
RBF	Função de base radial
RN	Rede neural
RN RBF	Rede neural por funções de base radial
SEM	Somatório de erros médios quadráticos

Introdução

O projeto de aeronaves, como todo projeto mecânico complexo, exige estudos de diversas disciplinas para amparar as decisões dos projetistas. Quando se analisam as etapas de um projeto, é bastante claro que na fase de projeto conceitual, as alterações necessárias têm um custo bem menor do que em fases posteriores, como mostra a Figura 1.1 (DE BAETS; MAVRIS, 2002). Portanto, é desejável possuir o maior número de informações possível nas etapas iniciais de projeto, para que sejam tomadas decisões corretas sem a necessidade de alterações posteriores. E isso envolve, entre outras coisas, a integração das várias áreas do conhecimento aeronáutico. Desta maneira, a necessidade por ferramentas de projeto mais avançadas e que façam uso dos poderosos recursos computacionais atuais, é evidente.

1.1 Otimização Multidisciplinar em Projeto

Uma filosofia que vem sendo utilizada para corresponder às necessidades citadas é a otimização multidisciplinar em projeto. O projeto de aeronaves por meio da abordagem de otimização multidisciplinar em projeto (do inglês, *Multidisciplinary Design Optimization* – MDO) é realizado utilizando modelos matemáticos integrados de aerodinâmica, estruturas, dinâmica de voo e sistemas, entre outros. Esta prática permite ao projetista atuar em parâmetros que geralmente não estão diretamente relacionados, por exemplo forma

Figura 1.1: Custo e impacto de alterações de projeto ao longo do tempo de desenvolvimento (DE BAETS; MAVRIS, 2002).

aerodinâmica e resistência estrutural, análises da interação fluido-estrutura e mecanismos, entre outros. O conceito de MDO é muito amplo e pode ser aplicado a diversos campos da ciência. Pode também ser aplicado em todos os estágios de um projeto, utilizando-se modelos matemáticos ajustados para cada um deles. Caixeta Jr. (2006) mostrou diversos sistemas de MDO que já foram desenvolvidos, dos quais alguns serão comentados a seguir.

Gallman et al. (1997) utilizaram dois códigos de MDO (ACSYNT-L e SPARROW) para otimizar um jato executivo avançado. A escolha por dois códigos de otimização foi feita para garantir os resultados de projeto e verificar eventuais erros nos métodos de análise. Estes sistemas incluem métodos de análise de desempenho de aeronaves em toda a missão (incluindo distâncias de pouso, velocidade de cruzeiro, teto de serviço, alcance, entre outros dados) e rotinas de otimização que permitem a obtenção de uma família de configurações ótimas. O objetivo de projeto é o peso vazio da aeronave, variando-se diversos parâmetros, como ângulo de enflechamento, razão de espessura pela corda da asa, área da asa, alongamento e margem estática. Como resultado foi obtida uma família de soluções para um jato executivo com oito lugares, capaz de transportar seis passageiros

por 5185 km um número de mach entre 0,81 e 0,85, com teto de serviço de 51000 pés, além de outras características.

Outro sistema de MDO é o ASTROS (do inglês, *Automated STRuctural Optimization System* - Sistema de Otimização Estrutural Automatizado), que já é comercializado e utilizado por diversas empresas e universidades e consiste em diversos módulos que são integrados para a busca das soluções ótimas de projeto estrutural. Os módulos principais são os de elementos finitos estruturais estático, dinâmico e de resposta em frequência, os de aerodinâmica estacionária e não-estacionária, subsônica e supersônica, e o módulo de otimização (JOHNSON e VENKAYYA, 1988 apud BISHOP et al., 1998).¹ Com estes é possível analisar ou otimizar o projeto de configurações dadas de aeronaves, de acordo com as necessidades do projetista.

Na área de desenvolvimento de mísseis, Tekinalp e Bingol (2004) implementaram um MDO para otimização das variáveis de projeto e de controle, juntamente com a trajetória do míssil, utilizando um processo iterativo com subdivisões igualmente espaçadas no tempo até o fim da combustão no motor, e com subdivisões igualmente espaçadas no consumo de energia, após o fim da combustão (*burnout*). Esse padrão de divisões foi comparado a outros e se mostrou o mais eficiente para este estudo. Entre os resultados apresentados pelos autores, pode-se destacar mísseis com alcance de 100 km de distância chegando a uma altitude entre 25 km e 30 km, dos quais diversas variáveis de projeto e controle foram determinadas pelo MDO.

Uma aplicação interessante de MDO é apresentada por Xiong et al. (2005). Trata-se da utilização de um sistema de otimização multidisciplinar para máquinas com turbinas complexas, chamado FIPER (do inglês, *federated intelligent product environment*), para uma aplicação industrial no projeto da estrutura de um combustor de motor à jato para aeronaves, conduzido pela General Electric. Os requisitos de projeto foram restrições práticas envolvendo áreas como termodinâmica, fadiga e dinâmica estrutural. Foi obtida

¹JOHNSON, E. H., VENKAYYA, V. B., *Automated Structural Optimization System (ASTROS), Volume I - Theoretical Manual*, Air Force Wright Aeronautical Labs., TR-88-3028/I, Wright-Patterson AFB, OH, dezembro 1988.

uma estrutura ótima para o combustor de um motor respeitando todos os requisitos de projeto, além de várias conclusões sobre a otimização e os métodos de modelagem empregados.

A otimização multidisciplinar em projeto também tem atraído a atenção dos pesquisadores e engenheiros de asas rotativas. Fusato e Celi (2006) apresentaram um estudo em que a dinâmica do rotor e a dinâmica de vôo foram simultaneamente consideradas para a maximização do amortecimento de um dos modos do rotor. A otimização trabalhou com oito variáveis de projeto referentes ao rotor, à estrutura e ao sistema de controle de vôo. Das restrições impostas pode-se destacar a estabilidade do rotor, as cargas no rotor e diversas restrições de qualidade de manuseio (do inglês, *handling qualities*) baseadas na ADS-33 (U.S. ARMY AVIATION AND MISSILE COMMAND, 2000). Obteve-se sucesso nos dois casos avaliados neste trabalho, ao alcançar um aumento de cerca de 90% no amortecimento do referido modo, com todas as variáveis satisfazendo os requisitos de projeto.

Para a área de asas adaptativas (do inglês, *morphing wings*) a utilização de MDO é também muito promissora. Maute e Reich (2006) trabalharam com um novo tratamento para a otimização multidisciplinar de mecanismos de estruturas aeronáuticas adaptativas, onde a otimização define o esquema do mecanismo, o número de atuadores e de pivôs a serem utilizados em uma asa adaptativa, juntamente com a definição das melhores formas para cada condição de vôo. O que se vinha fazendo anteriormente (método de dois passos) era otimizar a geometria da asa para atender aos requisitos aerodinâmicos de cada condição de vôo e então encontrar o mecanismo que levasse à essas geometrias. As soluções encontradas pelo esquema proposto foram bem melhores que as encontradas pelo método de dois passos, porém o custo computacional é cerca de dez vezes maior.

Na Coreia, Kim et al. (2006) realizaram uma otimização multidisciplinar aerodinâmica e estrutural para a asa de um caça supersônico coreano (T/A-50), com múltiplos objetivos, utilizando a metodologia de superfície de resposta. Foram definidas treze variáveis de projeto a serem otimizadas, sendo nove delas relativas a aerodinâmica da asa e do aerofólio

e outras quatro referentes a estrutura da asa. A otimização foi feita considerando várias condições de voo, e utiliza um algoritmo genético para controlar o peso de cada uma das condições. Como resultado, a asa obtida é muito semelhante à asa real da aeronave, que foi desenvolvida através de inúmeros ensaios em túnel de vento e estudos de custo-benefício, o que comprova a possibilidade da utilização do esquema de MDO desenvolvido como uma eficiente ferramenta de projeto conceitual.

Liu et al. (2006) propuseram um esquema de ajuste automático para o projeto conceitual de aeronaves e otimização. A idéia básica foi criar uma rede de conexões entre os vários componentes para a utilização de um sistema de projeto chamado *Synthetic Environment for Aircraft Conceptual Design* (SEACD) (LIU et al., 2004), de maneira que uma alteração em um dos componentes cause um ajuste automático nos outros através de relações e regras pré-definidas. Este MDO foi aplicado na otimização de um jato executivo conceitual para verificação do sistema proposto e foram obtidas duas configurações ótimas. Com a utilização de um sistema como este, gasta-se um pouco de tempo para criar as regras iniciais da rede de conexões, mas muitas vantagens são obtidas posteriormente, com a agilidade que o sistema traz ao projeto.

Diversos outros sistemas de MDO já estão em funcionamento e tem enorme valor, principalmente quando se buscam novos conceitos, para os quais não há banco de dados de aeronaves anteriores para serem utilizados como ponto de partida, como é o caso dos projetos de *Blended Wing and Body* (BWB), *C-wing* (asa em C), entre outros. São utilizados, considerando as mais diversas disciplinas, como estruturas, dinâmica de voo, desempenho, propulsão, aerodinâmica, controle, custos, entre outras. Embora a maioria dos trabalhos disponíveis na literatura tratem da aplicação de sistemas de MDO nas etapas de projeto preliminar e detalhado, já existem alguns considerando aplicações no projeto conceitual, como nos trabalhos de Raymer (2002), De Baets e Mavris (2002), De Baets (2004), Carty (2002), Antoine et al. (2004), Perez et al. (2004), Caixeta Jr. (2006), Abdalla (2009), Neufeld et al. (2009), Nunez et al. (2009).

Dentro do Departamento de Engenharia Aeronáutica da Escola de Engenharia de São Carlos (EESC - USP) foram realizados alguns trabalhos que buscaram criar ferramentas de otimização para o projeto de aeronaves. Widmaier (2005) criou um algoritmo genético para otimizar a estrutura de asas de veículos aéreos não tripulados (VANTs). Sua rotina trabalhava o número de camadas, espessuras e respectivas orientações do material compósito utilizado (incluindo fibra de vidro, fibra de aramida, espuma de PVC e matriz polimérica - resina epóxi) para obter a asa de menor massa estrutural. Caixeta Jr. (2006) criou um sistema de MDO para o projeto de asas flexíveis, inspirado em asas de VANTs do tipo HALE (do inglês *high altitude long endurance*, ou seja grande altitude e grande autonomia), que tendem a possuir grandes envergadura e alongamento, como mostram as Figs. 1.2 e 1.3. O sistema leva em conta a velocidade crítica de *flutter* e a massa estrutural como parâmetros de aptidão do algoritmo genético, buscando encontrar o melhor par de distribuições de rigidezes à flexão e à torção. Abdalla (2009) desenvolveu um ambiente de MDO complexo para projeto conceitual de aeronaves. O sistema utiliza técnicas de entropia estatística, desdobramento da função de qualidade (QFD), aritmética Fuzzi e algoritmos genéticos para obtenção de projetos ótimos, apresentando estudo de caso baseado em aeronaves de treinamento militar que permitam a transição entre as fases de treinamento básico e avançado. Este presente trabalho busca continuar o esforço do grupo pelo desenvolvimento do conceito de MDO e pelo aprofundamento de teorias relativas à sua implementação. Durante seu desenvolvimento, alguns artigos sobre os tópicos aqui tratados foram publicados e apresentados em conferências (DE MARQUI JR. et al., 2007) (CAIXETA JR. et al., 2008) (CAIXETA JR.; MARQUES, 2009b) (CAIXETA JR.; MARQUES, 2009a) (CAIXETA JR.; MARQUES, 2010).

1.1.1 MDO com Restrição Aeroelástica

A importância da aeroelasticidade no projeto de aeronaves foi percebida já no começo do século XX, após alguns acidentes devido ao *flutter*, que então não era bem conhecido. Entre os primeiros casos de *flutter* registrados, pode-se citar o do bombardeiro Handley

Figura 1.2: VANT HALE EuroHawk (derivado do Northrop Grumman RQ-4B Global Hawk) (ZAPKA, 2010).

Figura 1.3: VANT HALE MQ-9 Predator B (General Atomics/NASA Altair) (THOMAS, 2005).

Page 0/400, no início da Primeira Guerra Mundial, com estudos conduzidos a este respeito em 1916 (Lanchester, 1916 e Bairstow, Fage, 1916 apud BISPLINGHOFF et al., 1996).² ³ Caso semelhante a este ocorreu com a aeronave De Havilland DH-9 em 1917 e várias vidas foram perdidas até ser encontrada a solução para o problema. Nos casos acima, ambas aeronaves eram biplanos, que tem altas rigidezes torcionais, inerentes ao tipo de construção, tendo ocorrido *flutter* na cauda.

Quando se passou ao desenvolvimento de monoplanos, começaram a surgir os pro-

²Lanchester, F. W., *Torsional Vibration of the Tail of an Airplane*, Br. A.R.C., R. & M. 276, Part 1, July, 1916.

³Bairstow, L., Fage, A., *Oscillations of the Tailplane and Body of an Aeroplane in Flight*, Br. A.R.C., R. & M. 276, Part 2, July, 1916.

blemas aeroelásticos nas asas. Devido a insuficiente rigidez torcional, ocorreram perda de eficácia dos ailerons, deformações sob distribuição de carga e o *flutter* (BISPLINGHOFF et al., 1996). O primeiro exemplo registrado é do monoplano cantilever Fokker D-8, que apresentou problemas de rigidez torcional, devido ao dimensionamento ter sido feito através de critérios utilizados para biplanos. Como o desempenho desta aeronave era superior, ela era produzida e fornecida primeiro aos melhores pilotos e esquadrões. Assim, com os repetidos acidentes, temeu-se perder a nata da força aérea alemã e Anthony Fokker, por fim, descobriu o problema (Fokker, 1931 apud BISPLINGHOFF et al., 1996).⁴

Como tipicamente as estruturas de aeronaves são flexíveis e os fenômenos aeroelásticos devem ser avaliados para garantir a segurança dentro dos limites operacionais, a imposição de restrições aeroelásticas em uma metodologia de MDO, como um primeiro passo no desenvolvimento de um ambiente de MDO para dar suporte ao projeto conceitual, parece bastante adequada. Usualmente, as verificações aeroelásticas durante projetos de aeronaves ocorrem em um estágio avançado (DE BAETS, 2004). Ao trazer restrições aeroelásticas para a fase de projeto conceitual, a habilidade do projetista para definir as características da aeronave, evitando possíveis aumentos de custos devido a mudanças em estágios futuros, pode ser aprimorada. Já há alguns estudos de MDO com restrições aeroelásticas, para que este conhecimento esteja disponível nas fases iniciais. De maneira geral, utilizam modelos estruturais baseados no método de elementos finitos e modelos aeroelásticos, integrando-os a um otimizador, mas o enfoque dos trabalhos é bastante variado.

Bishop et al. (1998) investigaram o desempenho do código de MDO ASTROS no projeto otimizado de uma asa de baixo alongamento, do padrão de aviões de caça, utilizando duas modelagens de elementos finitos. Obtiveram modelos ótimos de projeto da asa, com um modelo bastante simplificado e outro mais refinado, aplicando restrições de resistência estrutural, reversão de aileron, e *flutter*, usando teorias aerodinâmicas subsônica e supersônica.

Percebendo a importância dos efeitos aeroelásticos no projeto de uma aeronave, o

⁴Fokker, A. H. G., *The Flying Dutchman*, Henry Holt and Co., Inc., 1931.

Instituto de Projeto de Aeronaves e Estruturas Leves (IFL), da Alemanha, decidiu aperfeiçoar seus métodos próprios de análise para que levassem em conta tais efeitos, tão cedo quanto possível, nos projetos conceitual e preliminar (OSTERHELD et al., 2000). Inicialmente, deu-se ênfase ao desenvolvimento e implementação de modelagens e métodos de análise avançados, tanto para estruturas como para aerodinâmica, aplicados no programa computacional PrADO (do inglês, *Preliminary Aircraft Design and Optimization Program* - Programa de Projeto Preliminar e Otimização de Aeronaves), também desenvolvido no IFL.

De Baets e Mavris (2002) definiram uma metodologia para a implementação de uma ferramenta de projeto para aeroelasticidade, para uso em ambiente de projeto conceitual, utilizando otimização estrutural com restrições de aeroelasticidade dinâmica. Este trabalho tratou dos métodos a serem utilizados, como o ASTROS e o ZAERO, este que é um modelo aeroelástico de alta fidelidade que se acopla prontamente ao ASTROS e fornece melhores resultados para as propriedades aeroelásticas. Posteriormente foi implementada a metodologia e avaliada em um caso base, no projeto de um jato executivo supersônico e silencioso (DE BAETS, 2004).

Bhatia et al. (2003) realizaram um trabalho de otimização de asas flexíveis de aeronaves de transporte subsônicas, onde a geometria e o dimensionamento estrutural são simultaneamente otimizados, levando em conta os efeitos de aeroelasticidade estática. O estudo foi feito utilizando a asa do Boeing 737-200 e foram otimizadas diversas variáveis referentes a geometria da asa e da estrutura.

Outro exemplo da utilização do ASTROS é apresentado por Jun et al. (2003), na otimização multidisciplinar no projeto de uma estrutura de asa com míssil em sua ponta. Foram considerados requisitos de resistência estrutural da asa sujeita a escoamento estacionário, bem como a velocidade crítica de *flutter*. Foram utilizados modelos de elementos finitos realísticos da estrutura da asa e do míssil e as variáveis de projeto foram diversas dimensões da estrutura da asa e as posições possíveis para o míssil. Foram obtidas es-

truturas otimizadas para a asa e das análises executadas conclui-se que a aerodinâmica do míssil tem grande influência no comportamento aeroelástico do sistema, uma vez que considerando apenas sua massa e desprezando sua aerodinâmica a velocidade de *flutter* é consideravelmente maior, e por isso utilizou-se a capacidade de otimização do ASTROS para melhorar as características aeroelásticas.

Estudo muito semelhante foi realizado por Janardhan e Grandhi (2004) também com o ASTROS. Enquanto o estudo anterior por Jun et al. (2003) foi realizado principalmente em regimes subsônico e supersônico, este trabalhou no regime transônico e comparou os resultados do ASTROS (aerodinâmica linear) com o de outro modelo aeroelástico que inclui aerodinâmica transônica não-linear, denominado CAP-TSD (BATINA et al., 1990). Porém, neste não foi considerada a influência aerodinâmica do corpo na ponta da asa. Os resultados obtidos mostram que a diferença das velocidades de *flutter* do ASTROS para o CAP-TSD não-linear são pequenas, tanto na região subsônica como na transônica. O ASTROS foi capaz de desenvolver uma asa ótima e factível com velocidade crítica aumentada no regime transônico.

Pode-se observar que estão sendo feitos vários estudos de MDO considerando a aeroelasticidade, mas de modo geral, ainda estão em fase inicial, tendo muito o que se aprofundar em relação aos modelos matemáticos e aos otimizadores, bem como a sua aplicação prática na indústria aeronáutica. É notório também que a maioria dos estudos são iniciados apenas com as asas das aeronaves, mas deverão em breve considerar aeronaves completas.

1.1.2 MDO com Utilização de Metamodelos

Esquemas típicos de MDO geralmente se deparam com problemas de alto custo computacional, o que impede uma busca apropriada pelo espaço de projeto e complica a integração de disciplinas. Uma alternativa para lidar com o desafio de reduzir o esforço computacional durante explorações vastas do espaço de projeto é o uso do conceito de

metamodelagem (WANG; SHAN, 2007), também pelo termo em inglês *surrogate modeling*. Define-se metamodelo como um modelo de modelo, que assume formas matemáticas simplificadas para aproximar funções que requerem grande esforço computacional para sua solução.

Diversos estudos sobre metamodelagem podem ser encontrados na literatura. Mullur e Messac (2006) estudaram a aplicação de funções de base radial estendidas para a metamodelagem de códigos de simulação computacionalmente caros, para aplicação em sistemas de MDO. Com base em parâmetros de avaliação como exatidão do metamodelo, efeitos da técnica de amostragem, efeitos do tamanho da amostra e da dimensão do problema, bem como da complexidade computacional, conclui-se que tal abordagem de metamodelagem é potencialmente poderosa para aplicações de MDO.

Wang e Shan (2007) fizeram uma grande revisão sobre métodos de metamodelagem e seu estado da arte, apresentando diversas técnicas categorizadas por tipo de amostragem, modelagem e ajuste de modelos. Percorrem diversas revisões bibliográficas anteriores, bem como várias aplicações de metamodelagens e apresentam vários pontos que ainda carecem de estudos, como por exemplo metamodelagem para problemas de larga escala (grande número de variáveis), metamodelagem flexível, amostragem inteligente e incertezas na metamodelagem.

Choi et al. (2008) utilizaram um sistema de MDO com múltiplas fidelidades (do inglês, *multifidelity*), ou seja, que inclui modelos de alta e média, ou baixa exatidão no mesmo sistema, para o projeto de jatos supersônicos com estrondo sônico de baixa intensidade. O sistema utiliza modelos de baixa ordem, metamodelos baseados em superfícies de resposta e somente utiliza modelos de alta exatidão nas regiões do domínio de solução onde os resultados apresentam erros grandes. Bons resultados foram obtidos e após cálculos de validação das soluções ótimas encontradas os erros apresentados foram inferiores a 4%.

Muitos outros trabalhos podem ser encontrados sobre técnicas de metamodelagens e também de aplicações de metamodelos. Para exemplificar o esforço em torno deste

assunto, pode-se citar os trabalhos de Viana e Haftka (2009), Viana et al. (2009a, 2009b, 2010) e Pineda et al. (2010). Dos trabalhos deste mesmo grupo (do Prof. Haftka, da Universidade da Flórida) existe um pacote de códigos computacionais (um *toolbox* para MATLAB®) que engloba vários códigos de metamodelagem e outros aplicativos úteis para criação de bancos de dados (planejamento de experimentos, conhecido pela expressão em inglês *design of experiments* – DOE), análises de erro e validação cruzada, entre outras funcionalidades, implementado por Viana (2010).

Técnicas de metamodelagem são capazes de melhorar o entendimento sobre as relações entre variáveis de entrada e saída, bem como de prover ferramentas para otimização e exploração do espaço de projeto que são mais rápidas que as análises computacionais convencionais, e finalmente, de simplificar a integração de códigos computacionais (SIMPSON et al., 2001). Deste modo, um metamodelo para previsão da velocidade de *flutter* parece muito adequado para ferramentas de MDO de projeto conceitual.

Dentro da revisão que Wang e Shan (2007) fizeram sobre metamodelos para aplicação em otimização de projetos de engenharia, podem ser destacadas algumas classes de metamodelos. Com base neste trabalho foram escolhidos dois metamodelos representantes de classes diferentes, a rede neural artificial, representando a classe dos métodos de aproximação e a interpolação por funções de base radial (funções que dependem somente da magnitude de um argumento - raio), representando os métodos de interpolação. Um terceiro tipo foi adotado, a rede neural por funções de base radial, por representar possivelmente uma integração das características das outras duas classes. Existem diversas outras técnicas de metamodelagem, porém os três aqui mencionados foram considerados os mais adequados para o objetivo proposto.

Quando se trabalha com metamodelos, atenção especial deve ser dada aos passos básicos a serem seguidos, que são: escolha de uma técnica de planejamento de experimentos (DOE); criação de bancos de dados (utilizando DOE); por fim, preparação do metamodelo.

A criação de um banco de dados para trabalhos de metamodelagem envolve a escolha criteriosa de conjuntos de soluções capazes de descrever as particularidades do domínio de solução, para permitir uma preparação adequada do metamodelo, o que justifica a utilização de DOE. Dentre as técnicas de DOE conhecidas, a que foi escolhida para ser utilizada neste estudo é chamada de teoria de amostragem de hipercubo latino (em inglês, *Latin Hypercube Sampling* - LHS) (WANG; SHAN, 2007).

Há um consenso entre os pesquisadores que para análises computacionais determinísticas, a técnica de planejamento de experimentos a ser utilizada deve ser de preenchimento de espaços (*space filling*, em inglês), como foi confirmado por Simpson et al. (1998). As técnicas de Vetores Ortogonais e LHS estão classificadas como métodos de preenchimento de espaço, sendo o LHS considerado mais preciso que a Amostragem Aleatória e que a Amostragem Estratificada para estimar as médias, variâncias e funções de distribuição de uma saída (WANG, 2003). Wang (2003) também afirma que o LHS garante que cada uma das variáveis de entrada tenha todas as porções de sua faixa de trabalho representadas. Ademais, observa-se que o LHS pode lidar com muitas variáveis de entrada e é computacionalmente barato de se produzir.

1.1.3 MDO Baseado em Algoritmos Genéticos

Uma questão importante surge durante a criação de ferramentas para otimização, que é a escolha do método de otimização a ser utilizado, visto que há diversas metodologias disponíveis. Hajela (1999) afirma que para problemas com variáveis discretas existe uma dificuldade em se utilizar métodos de gradiente, pois é necessário fazer adaptações criando múltiplos problemas contínuos equivalentes. Para problemas de muitas dimensões este esquema torna-se inviável, o que pode ser comprovado pela pequena quantidade de trabalhos de MDO utilizando métodos de otimização baseado em gradientes. E além disso, estes métodos têm uma propensão à convergir para ótimos relativos (ótimos locais) muito próximos ao ponto de partida, o que se torna uma limitação grave.

Entre os métodos que não são baseados em gradientes, diversos serão citados a seguir (HAJELA, 1999). Os métodos de ordem zero para busca local podem ser divididos em determinísticos - método de busca de padrões de Hooke e Jeeves (HOOKE; JEEVES, 1961), método de Rosenbrock (ROSENBROCK, 1960) e método de Powell (POWELL, 1964) - e estocásticos - métodos de busca aleatória. Semelhantemente, os métodos de busca globais se dividem em determinísticos - métodos de particionamento (PINTER, 1995; HANSEN, 1992), método de programação quadrática sequencial (BIGGS, 1975) e métodos de aglomeração (TORN; ZILINSKAS, 1989) - e estocásticos - método de *Simulated Annealing* (KIRKPATRICK et al., 1983), método de Algoritmo Genético (HOLLAND, 1975; GOLDBERG, 1989) este extensamente utilizado em trabalhos de MDO.

Baseado nas teorias evolucionárias de Charles Darwin e Ronald A. Fisher, bem como de outras teorias de genética de seres vivos, o AG é um método que lida com a evolução de populações de soluções. Cada solução é adequadamente codificada como um cromossomo e o procedimento básico dos AGs imita o processo biológico natural, com cruzamentos semi-aleatórios entre os indivíduos (pais), gerando novos indivíduos (filhos), sendo possível a ocorrência ocasional de mutação. Após os cruzamentos, os melhores indivíduos são selecionados, descartando-se os piores, como na seleção natural das espécies.

Esse método foi criado por John H. Holland (HOLLAND, 1975) e sua equipe (DE JONG, 1975, 1980) na Universidade de Michigan e tem sido muito utilizado pela robustez inerente. O AG não apresenta grandes tendências de encontrar ótimos locais, uma vez que não percorre um “caminho” (como os métodos de gradiente) em busca da melhor solução, mas utiliza um procedimento que tende a selecionar indivíduos (soluções) de regiões distintas do domínio de soluções. Além disso, a implementação dos AGs em geral é muito simples, o que se torna mais um atrativo do método.

Khatib e Fleming (1997) fizeram uma revisão sobre computação evolucionária para aplicação em MDO. Concluíram que os AGs pertencem a um grupo de sistemas de solução mais abrangente, dos chamados algoritmos evolucionários, do qual também fazem parte

os seguintes: programação evolucionária, estratégias de evolução, programação genética e sistemas classificadores. Contudo, na comunidade de MDO, o mais utilizado deles àquela época e ainda hoje é o algoritmo genético.

A utilização de um AG para o projeto preliminar de asas subsônicas foi apresentada por Anderson e Gebert (1996). Os objetivos foram a otimização da razão de sustentação por arrasto (L/D) variando-se a forma aerodinâmica, com a restrição estrutural de a asa não quebrar sob os carregamentos especificados. As soluções de Pareto (conjunto das soluções que para ter uma característica melhorada deve ter outra piorada) encontradas mostram a capacidade do AG de determinar asas de alta eficiência, mantendo boa sustentação e boa resistência aos carregamentos.

Roth e Crossley (2003) aplicaram técnicas de otimização no projeto conceitual de aeronaves adaptativas (*morphing aircraft*). A proposta do trabalho foi determinar quais características deveriam ser mutáveis e qual a quantidade destas mutações, sendo necessário modelar as mutações como uma variável independente. Entre os métodos de otimização testados, vários problemas de convergência se sucederam devido às descontinuidades do equacionamento adotado, sendo que apenas o algoritmo genético foi capaz de cumprir o papel eficazmente. Foram obtidos diversos dados a serem mutáveis em regimes diferentes de voo, como razão de peso-empuxo, ângulo de enflechamento, alongamento, em condições de subida, cruzeiro, *loiter* (como é chamado o procedimento de voar em círculos próximo ao aeroporto enquanto se espera a liberação para pouso), entre outras.

Para o projeto preliminar de estruturas de asas do tipo caixão (do inglês, *wing box*), com restrição de torção máxima, Kapania e Chun (2004) utilizaram três métodos de otimização, sendo que o AG foi utilizado primeiro para determinação de ótimo local, uma vez que tem reconhecida robustez. Depois foram utilizados dois métodos de gradiente (gradiente conjugado e descida mais íngreme - do inglês, *steepest-descent*) e os resultados foram comparados aos obtidos pelo AG. No trabalho de Kapania e Chun (2004) percebe-se a grande confiabilidade creditada ao método de otimização por algoritmos genéticos.

Liu (2005) propôs um algoritmo genético com algumas alterações no operador cruzamento, ao qual chamou de algoritmo genético inteligente, e fez a aplicação deste na otimização da aerodinâmica de aeronaves, trabalhando tanto o aerofólio como geometria em planta, tendo vários parâmetros trabalhados para a redução do arrasto. Duas aeronaves avançadas foram utilizadas para esta aplicação, sendo uma delas um avião de defesa e a outra, o caça F-16A, tendo-se obtido uma redução de arrasto total de 2,18% e 1,86%, respectivamente. As alterações impostas propiciaram um melhor desempenho no AG e demonstram mais uma vez a grande versatilidade e liberdade que o método oferece.

Mediante os novos estudos para o desenvolvimento de novas aeronaves de transporte supersônicas, Arizono e Isogai (2005) desenvolveram um código para a otimização da estrutura de uma asa tipo *cranked-arrow* (em inglês, flecha dobrada, como a do protótipo F-16XL), baseada na configuração em estudo pela Boeing, que considera a resistência ao carregamento estacionário, flambagem localizada e análises aeroelásticas. A estrutura da asa é de material composto laminado e utilizou-se um AG para determinar a forma de laminação ótima, para o menor peso estrutural, respeitando os fatores já citados. Foram obtidas soluções que satisfazem todos os requisitos, determinando-se assim os ângulos de laminação e espessura necessárias para a estrutura de uma asa com velocidade crítica de *flutter* de 372,3 m/s.

Antoine e Kroo (2005) exploraram a possibilidade de se integrar estudos de ruídos e emissões de poluentes como objetivos de otimização, para aplicação em projeto conceitual. A ferramenta de projeto faz análises comparativas levando em conta os aspectos ambientais e o custo operacional, sendo a otimização realizada por um algoritmo genético multiobjetivo. Entre os códigos utilizados, destacam-se o programa de previsão de ruídos (do inglês, *Aircraft Noise Prediction Program* - ANOPP) desenvolvido pelo Centro de Pesquisa NASA Langley, o código de desempenho de motores desenvolvido pelo Centro de Pesquisa NASA Glenn e os módulos de projeto, análise e otimização de aeronaves desenvolvidos na Universidade de Stanford, Califórnia.

Uma abordagem de otimização que tem sido bastante utilizada em problemas de MDO é a otimização multiobjetivo, que além de trabalhar com diversas disciplinas ao mesmo tempo também procura aperfeiçoar as soluções com relação a vários objetivos. Nemec et al. (2004) trabalharam na otimização de forma aerodinâmica de aerofólios multi-elementos utilizando modelos baseados nas equações compressíveis de Navier-Stokes em conjunto com um modelo de turbulência. Embora não seja uma otimização multidisciplinar, trata-se da abordagem multiobjetivo ao otimizar aerofólios para melhora de sustentação em configuração de decolagem e também otimizando configurações com restrição de sustentação para várias condições de operação transônicas. Os autores apresentam também um algoritmo para criação da fronteira de Pareto e validam os resultados com um algoritmo genético.

Outro trabalho semelhante foi desenvolvido por um grupo israelense, onde Epstein e Peigin (2004) aplicaram modificações a um algoritmo genético para trabalhar, sob o conceito multiobjetivo, na otimização de forma de aerofólios transônicos. A modelagem aerodinâmica também é baseada em métodos de Navier-Stokes, porém é criada uma base de dados com os modelos numéricos para então produzir um modelo de ordem reduzida a ser utilizado no ambiente de otimização. Obtiveram um grande ganho de tempo computacional que permitiu a utilização do sistema em um exigente ambiente de projeto de engenharia.

Keane (2006) apresentou uma abordagem de otimização multiobjetivo utilizando métodos de planejamento de experimentos (conhecido em inglês como *design of experiments* - DOE) e metamodelagens por superfícies de resposta para construir a fronteira de Pareto. Os métodos utilizados são extensões de métodos para buscas de objetivo único. São feitas comparações com buscas multiobjetivos baseadas em algoritmo genético com seleção por não-dominância (do inglês, *nondominated sorting genetic algorithm* - NSGA-II), de onde se conclui que os resultados são coerentes e a abordagem tem potencial para futuras aplicações.

Como já se observa por alguns destes trabalhos, o problema da otimização multi-objetivo consiste em um conceito mais amplo, porque não se obtém uma única solução, mas um conjunto de soluções ótimas, às quais normalmente se dá o nome de fronteira de Pareto (PARETO, 1906). Uma ampla revisão de métodos de otimização multiobjetivo pode ser encontrada no trabalho de Marler e Arora (2004).

1.2 Objetivos

O intuito deste trabalho é estudar a organização de um sistema de MDO com restrição aeroelástica para o projeto de asas, utilizando metamodelagem para previsão da velocidade crítica de *flutter*. Este estudo considera variáveis estruturais e geométricas como as de projeto. A velocidade crítica de *flutter* e a massa estrutural da asa são os parâmetros de avaliação de um algoritmo genético (AG) multiobjetivo com seleção por não-dominância (DEB, 2001). Um metamodelo é utilizado para a obtenção da velocidade de *flutter* e a massa estrutural, em substituição aos modelos numéricos originais, acelerando assim o processo global de MDO.

Os modelos numéricos originais consistem nos seguintes modelos matemáticos: um modelo baseado no método dos elementos finitos (MEF) para cálculos de dinâmica estrutural, um modelo de aerodinâmica não-estacionária baseado na teoria das faixas e em escoamento potencial linear, um modelo de solução aeroelástica para previsão de *flutter* baseado no método K.

Neste trabalho são apresentados resultados e discussões sobre o desempenho do MDO baseado em metamodelos. Atenção especial é dada aos ganhos no custo computacional. Outro aspecto importante da metamodelagem é relacionado ao banco de dados para o processo de criação dos metamodelos. Também são estudadas algumas metodologias de metamodelagem de maneira a decidir sobre qual deve ser empregada no MDO.

Conforme se observa pela revisão bibliográfica apresentada, foram realizados trabalhos de MDO incluindo aeroelasticidade em estágio de projeto preliminar, para aeronaves que

operam em regime transônico ou supersônico. Não foi encontrado, contudo, nenhum que empregue técnicas de metamodelagem para tal fim, nem algum que focasse o regime de voo característico dos VANTs HALE ou MALE (do inglês *medium altitude long endurance*, ou seja, altitudes de voo médias e grande autonomia), que é subsônico. Assim, este trabalho busca contribuir ao explorar técnicas de metamodelagem para previsão de *flutter* e os benefícios de sua utilização em sistemas de MDO. Visa a contribuir também com o projeto conceitual de aeronaves, ao criar a oportunidade de inserir a previsão de *flutter* entre as disciplinas utilizadas nesta fase inicial do projeto, aumentando a quantidade de informações à disposição do projetista. Por fim, foca o regime de voo e as características básicas dos VANTs HALE ou MALE, ou seja, regime subsônico e asas com grandes envergaduras e alongamentos, conforme aqueles vistos nas Figs.1.2 e 1.3.

1.3 Estrutura da Tese

Neste trabalho são apresentados os modelos matemáticos utilizados para os cálculos da dinâmica-estrutural de uma asa flexível, da previsão da velocidade crítica de *flutter* através de modelo aeroelástico, bem como de três diferentes metamodelos. São também apresentados o funcionamento básico do método de otimização por algoritmos genéticos e as particularidades do AG implementado.

O capítulo 2 inicialmente mostra o equacionamento básico do modelo em elementos finitos empregado e suas entradas e saídas. Passa então por uma breve explicação do modelo aerodinâmico não-estacionário usado no modelo aerolástico e em seguida descreve o funcionamento deste, a técnica de solução de *flutter* por ele utilizada e também, suas entradas e saídas. Introduz então algumas particularidades da modelagem, para prosseguir apresentando os três metamodelos considerados aqui.

As descrições da organização do processo de MDO, do funcionamento do método de AG e de um AG simples, assim como de algumas particularidades da otimização multiobjetivo são feitas no capítulo 3, onde são descritos os operadores básicos, os procedimentos

típicos do método bio-inspirado e os detalhes de sua implementação. O capítulo 4 traz detalhes da criação dos bancos de dados e algumas particularidades destes bancos, apresenta os resultados da preparação dos metamodelos e a escolha de um deles para aplicação nas otimizações. Traz ainda resultados do desempenho do AG e escolha de seus parâmetros e, por fim, dois estudos de caso.

Finalmente, o capítulo 5 apresenta as conclusões deste trabalho enquanto o capítulo 5 apresenta algumas sugestões para trabalhos futuros.

Previsão de Flutter e Metamodelagem

2.1 Solução Aeroelástica

O modelo implementado para solução de *flutter* é baseado no de Silva (1994) e as informações da dinâmica estrutural são obtidas através de um modelo em elementos finitos (MEF). De uma forma geral, o funcionamento esquematizado no diagrama da Figura 2.1 representa a solução do problema aeroelástico. São necessárias entradas que descrevam os modos e frequências naturais da estrutura, bem como outras que definam parâmetros referentes ao modelo aerodinâmico tridimensional para serem usados na modelagem de teoria das faixas e Theodorsen. Do modelo estrutural já se obtém também os parâmetros para o método de solução de *flutter*. O modelo resolve então um problema de auto-valor utilizando o método K (HODGES; PIERCE, 2002). Os valores de frequência, amortecimento e velocidade são as saídas fornecidas para cada modo, a partir dos quais são geradas as curvas V - g - f (como são chamadas as curvas de amortecimento contra velocidade e frequência contra velocidade, normalmente utilizadas em estudos de aeroelasticidade), de onde se obtém a velocidade crítica e a frequência de *flutter* para o respectivo modo crítico.

Figura 2.1: Diagrama do funcionamento do modelo aeroelástico.

2.1.1 Modelo Dinâmico-Estrutural

Para a obtenção das características dinâmico-estruturais da asa em estudo, optou-se por desenvolver um modelo matemático usando o método dos elementos finitos. Esta escolha foi feita pela possibilidade de adequar facilmente os resultados modais às entradas necessárias ao modelo aeroelástico.

O método dos elementos finitos foi sugerido inicialmente por Courant (1943 apud MEIROVITCH, 1980)¹, mas o desenvolvimento do método como é conhecido hoje é creditado a dois trabalhos da área de aeronáutica (TURNER et al., 1956 e MELOSH, 1963 apud MEIROVITCH, 1980)^{2 3}. Ele consiste na discretização de uma estrutura contínua em elementos delimitados por pontos, chamados nós, onde condições de compatibilidade de movimentos e equilíbrio de forças internas são aplicadas (MARQUES, 1993). Com a imposição destas condições, o conjunto dos elementos finitos se comporta como um corpo

¹Courant, R. Variational Methods for Solution of Problems of Equilibrium and Vibrations, *Bulletin of the American Mathematical Society*, v. 49, p. 1-23, jan. 1943.

²Turner, M. J.; Clough, R. W.; Martin, H. C.; Topp, L. J. Stiffness and Deflection Analysis of Complex Structures, *Journal of Aeronautical Sciences*, v. 23, p. 805-823, 1956

³Melosh, R. J. Basis for Derivation of Matrices for the Direct Stiffness Method, *AIAA Journal*, v. 1, n. 7, p. 1631-1636, 1963

contínuo. Mais detalhes sobre os fundamentos do método de elementos finitos podem ser encontrados em: Meirovitch (1980), Craig (1981), Melosh (1990), Marques (1993) e Soriano (2003).

Diversos tipos de elementos foram desenvolvidos, para os mais diversos e complexos tipos de estruturas. Para aplicações em pás de helicópteros, como nos trabalhos de Marques (1993) e Gasparini (2004), assim como em asas de geometria comum, como no trabalho de Caixeta Jr. (2006), é possível utilizar o elemento de viga de Bernoulli-Euler, tendo sido este o elemento escolhido para a implementação do presente modelo.

O elemento de viga de Bernoulli-Euler (CRAIG, 1981), representa uma viga com propriedades constantes ao longo de seu comprimento, dois nós (em suas extremidades), com seis graus de liberdade cada, como mostra a Figura 2.2. Para o caso estudado, ou seja, uma longarina de asa cujos modos devem ser determinados para os cálculos de previsão de *flutter*, os graus de liberdade do elemento que representam os deslocamentos na direção da envergadura (eixo y), na direção da corda (eixo x) e rotação em torno do eixo vertical (eixo z), respectivamente u_1 e u_7 , u_3 e u_9 , u_5 e u_{11} na Figura 2.2, não têm influência relevante para descrever o movimento do *flutter* e foram, portanto, desconsiderados.

Figura 2.2: Elemento de viga de Bernoulli-Euler (CRAIG, 1981).

Empregou-se então um modelo com elementos de 3 graus de liberdade por nó (Figura 2.3), sendo estes um deslocamento vertical (eixo z) e uma rotação em torno do eixo x (longitudinal da aeronave), respectivamente u_1 e u_3 , para representar a flexão, e uma

rotação em torno do eixo y (u_2 na direção da longarina), para representar a torção. A Figura 2.3 mostra os graus de liberdade do elemento utilizado. Caixeta Jr. (2006) apresentou resultados utilizando elementos com esta configuração e concluiu que representam adequadamente os modos de vibrar da estrutura que influenciam o *flutter*.

Figura 2.3: Graus de liberdade do elemento de viga utilizado.

Para representar a forma das deformações dos elementos, quando sujeitos aos carregamentos, são utilizadas funções de forma, que transformam os deslocamentos elásticos da estrutura em deslocamentos nodais:

$$\begin{aligned} z &= \psi_1 u_1 + \psi_2 u_3 + \psi_3 u_4 + \psi_4 u_6 \\ \phi_h &= \psi_5 u_2 + \psi_6 u_5 \end{aligned} \quad , \quad (2.1)$$

onde as funções ψ_i são os polinômios de Hermite:

$$\begin{aligned} \psi_1 &= 1 - 3 \left(\frac{y}{l_e} \right)^2 + 2 \left(\frac{y}{l_e} \right)^3 \\ \psi_2 &= y - 2l_e \left(\frac{y}{l_e} \right)^2 + l_e \left(\frac{y}{l_e} \right)^3 \\ \psi_3 &= 3 \left(\frac{y}{l_e} \right)^2 - 2 \left(\frac{y}{l_e} \right)^3 \\ \psi_4 &= -l_e \left(\frac{y}{l_e} \right)^2 + l_e \left(\frac{y}{l_e} \right)^3 \\ \psi_5 &= 1 - \frac{y}{l_e} \\ \psi_6 &= \frac{y}{l_e} \end{aligned} \quad . \quad (2.2)$$

A partir destas equações, é possível então encontrar as expressões para rigidez e massa:

$$\begin{aligned}
 k_{ij} &= \int_0^{l_e} EI \psi_i'' \psi_j'' dy & \text{para } i = 1, 2, 3, 4 \text{ e } j = 1, 2, 3, 4 \quad , \\
 k_{ij} &= \int_0^{l_e} GJ \psi_i' \psi_j' dy & \text{para } i = 5, 6 \text{ e } j = 5, 6 \quad , \\
 m_{ij} &= \int_0^{l_e} \rho A \psi_i \psi_j dy & \text{para } i = 1, 2, 3, 4 \text{ e } j = 1, 2, 3, 4 \quad , \\
 m_{ij} &= \int_0^{l_e} \rho J \psi_i \psi_j dy & \text{para } i = 5, 6 \text{ e } j = 5, 6 \quad ,
 \end{aligned} \tag{2.3}$$

onde $()' = \frac{d()}{dy}$ e $()'' = \frac{d^2()}{dy^2}$.

A partir destas expressões, as matrizes de rigidez e massa de cada elemento são montadas:

$$[K_e] = \begin{bmatrix} \frac{12EI}{l_e^3} & 0 & \frac{6EI}{l_e^2} & \frac{-12EI}{l_e^3} & 0 & \frac{6EI}{l_e^2} \\ 0 & \frac{GJ}{l_e} & 0 & 0 & \frac{-GJ}{l_e} & 0 \\ \frac{6EI}{l_e^2} & 0 & \frac{4EI}{l_e} & \frac{-6EI}{l_e^2} & 0 & \frac{2EI}{l_e} \\ \frac{-12EI}{l_e^3} & 0 & \frac{-6EI}{l_e^2} & \frac{12EI}{l_e^3} & 0 & \frac{-6EI}{l_e^2} \\ 0 & \frac{-GJ}{l_e} & 0 & 0 & \frac{GJ}{l_e} & 0 \\ \frac{6EI}{l_e^2} & 0 & \frac{2EI}{l_e} & \frac{-6EI}{l_e^2} & 0 & \frac{4EI}{l_e} \end{bmatrix} , \tag{2.4}$$

$$[M_e] = \frac{\rho_e A l_e}{420} \begin{bmatrix} 156 & 0 & 22l_e & 54 & 0 & -13l_e \\ 0 & \frac{140J}{A} & 0 & 0 & \frac{70J}{A} & 0 \\ 22l_e & 0 & 4l_e^2 & 13l_e & 0 & -3l_e^2 \\ 54 & 0 & 13l_e & 156 & 0 & -22l_e \\ 0 & \frac{70J}{A} & 0 & 0 & \frac{140J}{A} & 0 \\ -13l_e & 0 & -3l_e^2 & -22l_e & 0 & 4l_e^2 \end{bmatrix} . \tag{2.5}$$

Uma vez calculadas as matrizes do elemento, a montagem das matrizes globais de rigidez e massa é feita através da superposição das matrizes de cada elemento (MARQUES, 1993). Neste processo cumulativo é utilizada uma matriz auxiliar formada de zeros e uns dispostos de forma diferenciada para cada elemento finito. Sua dimensão é $g_l \times g_l(N+1)$, onde g_l é o número de graus de liberdade de cada nó e N é o número de elementos. As matrizes dos elementos devem obedecer a sequência destes na estrutura, sendo a matriz auxiliar criada com a seguinte regra:

$[A_{k^*}^{aux}](i, j) = 1$ para $i = 1, 2, \dots, g_l$ e $j = (k^* - 1)g_l + 1, (k^* - 1)g_l + 2, \dots, (k^* - 1)g_l + g_l$;

$[A_{k^*}^{aux}](i, j) = 0$ para os demais pares (i, j) ;

onde k^* representa o k^* -ésimo elemento finito.

As matrizes globais são formadas com o acúmulo dos sucessivos resultados obtidos com este processo, para cada elemento finito. Para exemplificar, o k^* -ésimo passo na montagem da matriz global é dado por:

$$[M_g] = [M_O] + [A_{k^*}^{aux}]^T [M_e] [A_{k^*}^{aux}] \quad \text{para } k^* = 1, 2, \dots, N \quad ;$$

onde $[M_O]$ é a matriz de massa acumulada até o passo $(k^* - 1)$.

Um sistema aeroelástico geral, sem amortecimento estrutural, pode ser representado pela equação:

$$[M_g] \{\ddot{u}(t)\} + [K_g] \{u(t)\} = \{C_a\} \quad , \quad (2.6)$$

onde $[M_g]$ e $[K_g]$ são respectivamente as matrizes globais de massa e rigidez, $\{u(t)\}$ é um vetor de posições e $\{C_a\}$ é o vetor de carregamento aerodinâmico.

Para se conhecer as características dinâmicas da estrutura, deve-se obter as frequências naturais e os modos de vibração, resolvendo para tanto, a equação do movimento para vibração livre, representada pela seguinte equação matricial:

$$[M_g] \{\ddot{u}(t)\} + [K_g] \{u(t)\} = 0 \quad . \quad (2.7)$$

Considerando-se a hipótese de movimento harmônico, descreve-se então:

$$\{u(t)\} = \{U\} \cos(\omega t - \beta_f) \quad , \quad (2.8)$$

que substituído na equação (2.7), resulta no problema de auto-valores:

$$([K_g] - \omega_n^2 [M_g]) \{U\} = 0 \quad . \quad (2.9)$$

Como soluções deste problema resultam as frequências naturais (auto-valores - ω_n) e

os modos naturais (auto-vetores referentes a cada auto-valor - $\{U\}$). McConnell (1995) apresentou uma importante dedução onde, para quaisquer pares de auto-valores ω_r e ω_s :

$$([K_g] - \omega_r^2 [M_g]) \{U_r\} = 0 \implies [K_g] \{U_r\} = \omega_r^2 [M_g] \{U_r\} \quad (2.10)$$

e

$$([K_g] - \omega_s^2 [M_g]) \{U_s\} = 0 \implies [K_g] \{U_s\} = \omega_s^2 [M_g] \{U_s\} \quad . \quad (2.11)$$

Pré-multiplicando cruzado os vetores transpostos dos auto-vetores, tem-se então:

$$\{U_s\}^T [K_g] \{U_r\} = \omega_r^2 \{U_s\}^T [M_g] \{U_r\} \quad (2.12)$$

e

$$\{U_r\}^T [K_g] \{U_s\} = \omega_s^2 \{U_r\}^T [M_g] \{U_s\} \quad , \quad (2.13)$$

que com $\omega_r \neq \omega_s$ resulta em:

$$\{U_r\}^T [M_g] \{U_s\} = 0 \quad (2.14)$$

e

$$\{U_r\}^T [K_g] \{U_s\} = 0 \quad , \quad (2.15)$$

de onde se pode concluir que as formas dos modos associados com diferentes frequências naturais são inercial e elasticamente ortogonais (independentes), ou seja, os modos são desacoplados. Os movimentos do sistema podem ser representados por uma combinação linear dos movimentos de cada modo natural, pelo princípio da superposição (CRAIG, 1981), podendo-se inclusive trabalhar apenas com alguns modos de interesse.

Uma das conseqüências da ortogonalidade é a obtenção das matrizes $[M_{gen}]$ e $[K_{gen}]$:

$$[U]^T [M_g] [U] = [M_{gen}] \quad (2.16)$$

e

$$[U]^T [K_g] [U] = [K_{gen}] \quad , \quad (2.17)$$

que são as matrizes de massa e rigidez generalizadas, que novamente demonstram que o

sistema é desacoplado por serem diagonais.

Considerando a seguinte transformação linear de coordenadas para o espaço modal $(\eta(t))$:

$$\{u(t)\} = [U] \{\eta(t)\} \quad , \quad (2.18)$$

aplicando na equação (2.6), pré multiplicando por $[U]^T$ e pós multiplicando por $[U]$, chega-se em:

$$[U]^T [M_g] [U] \{\ddot{\eta}(t)\} + [U]^T [K_g] [U] \{\eta(t)\} = [U]^T \{C_a\} \quad , \quad (2.19)$$

ou seja:

$$[M_{gen}] \{\ddot{\eta}(t)\} + [K_{gen}] \{\eta(t)\} = [U]^T \{C_a\} \quad . \quad (2.20)$$

Então, resolvido o problema de auto-valores e auto-vetores, e definidos os modos de interesse a serem utilizados, já se tem os dados de entrada referentes à estrutura da asa, necessários para o modelo aeroelástico, ou seja, para cada frequência natural, a forma dos modos de flexão e torção desacoplados (representados por deslocamento vertical e rotação de cada faixa), as massas e rigidezes generalizadas.

2.1.2 Modelo Aerodinâmico

Para a representação das forças e momentos sobre a asa, emprega-se um modelo aerodinâmico baseado na teoria das faixas (YATES JR., 1966). Este modelo parte da idéia de modelar escoamentos aerodinâmicos tridimensionais através de formulações bidimensionais.

A Figura 2.4 mostra uma discretização típica para o método, onde cada uma das faixas ao longo da envergadura é tratada como uma seção bidimensional. Esta teoria não considera os efeitos de ponta de asa, nem a influência de uma faixa sobre a outra, mas para asas de grande alongamento e com poucas variações das características aerodinâmicas ao longo das faixas, os resultados são bastante satisfatórios. Utiliza a informação da derivada da curva do coeficiente de sustentação (C_{L_α}), que é fornecida por um modelo

Figura 2.4: Discretização em faixas (SILVA, 1994).

da aerodinâmica estacionária tridimensional, conforme ilustra a Fig.2.1. Este modelo é baseado no método de malha de vórtices e consiste em uma modelagem potencial do escoamento através de anéis de vórtices distribuídos sobre a superfície da asa. Mais detalhes desta modelagem e do código utilizado pode ser encontradas no livro de Stribling (1984).

Para cada faixa, aplica-se a formulação de Theodorsen (THEODORSEN, 1934), que representa o carregamento aerodinâmico não-estacionário para escoamento incompressível e potencial, à pequenas perturbações. Esta modelagem utiliza singularidades aerodinâmicas para representar o escoamento sobre um aerofólio em movimento harmônico simples. Duas partes compõem o escoamento através das singularidades, uma circulatória (esteira de vórtices) e outra não-circulatória (fontes no extradorso e no intradorso do aerofólio) e os respectivos cálculos dos potenciais de velocidades são efetuados separadamente. Com estes potenciais, é possível integrar a distribuição de pressão sobre a corda e obter as forças e momentos sobre o aerofólio.

O carregamento aerodinâmico não-estacionário sobre a superfície de sustentação tridimensional é obtido somando-se os valores de forças e momentos calculados para cada faixa. Estes são definidos através de uma matriz de coeficientes de influência (SILVA, 1994) em

função das coordenadas de deslocamento do sistema, ou seja:

$$\begin{Bmatrix} L_f \\ M_f \end{Bmatrix} = -\pi\rho S_f \omega^2 b^4 [Q(k)] \begin{Bmatrix} \frac{h}{b} \\ \alpha \end{Bmatrix}, \quad (2.21)$$

onde, ρ é a densidade do ar, S_f é a área da faixa, ω é a frequência do movimento, b é a semi-corda da faixa e $[Q(k)]$ é a matriz de coeficientes de influência no domínio da frequência reduzida ($k = \frac{\omega c}{V}$). Esta matriz avalia quanto um grau de liberdade influencia o carregamento associado a outro grau de liberdade. Discriminam-se ainda as variáveis c , que é a corda da faixa e V , a velocidade do escoamento não perturbado. Por fim, L_f e M_f são, respectivamente, a força de sustentação e o momento de arfagem sobre a faixa, h é o deslocamento vertical e α é o ângulo de ataque. As variáveis h e α estão relacionadas às variáveis estruturais: $h = u_1$ e $\alpha = u_2$, com u_1 e u_2 ilustradas na Figura 2.3.

Mais detalhes sobre a montagem da matriz de coeficientes de influência podem ser encontrados no trabalho de Theodorsen e Garrick (1942).

Para a asa inteira, a matriz de coeficientes de influência é montada a partir das matrizes de cada faixa, resultando em uma matriz diagonal por blocos, cada um dos blocos correspondente a uma faixa. Esta montagem é exemplificada na equação:

$$[Q_{tot}(k)] = \begin{bmatrix} [Q_1(k)] & 0 & 0 & \cdots & 0 \\ 0 & [Q_2(k)] & 0 & \cdots & 0 \\ 0 & 0 & [Q_3(k)] & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & [Q_{nf}(k)] \end{bmatrix}, \quad (2.22)$$

onde nf é o número de faixas e os índices 1, 2, 3, $\dots$, nf representam as faixas.

A matriz $[Q_{tot}(k)]$ é diagonal por blocos porque não existe influência aerodinâmica de uma faixa sobre outra. O carregamento aerodinâmico total é então definido como:

$$\{C_a\} = -\pi\rho S_f \omega^2 b^4 [Q_{tot}(k)] \{x_a(t)\}, \quad (2.23)$$

onde $\{x_a(t)\}$ é o vetor dos deslocamentos no sistemas de coordenadas aerodinâmicas e é definido como:

$$\{x_a(t)\} = \begin{bmatrix} \{x_1(t)\}^T & \{x_2(t)\}^T & \{x_3(t)\}^T & \dots & \{x_{nf}(t)\}^T \end{bmatrix}^T, \quad (2.24)$$

sendo que para a l -ésima faixa:

$$\{x_l(t)\} = \begin{Bmatrix} \frac{h_l}{b}(t) \\ \alpha_l(t) \end{Bmatrix}. \quad (2.25)$$

Por conveniência, a equação (2.23) pode ser reescrita:

$$\{C_a\} = q_\infty [A(k)] \{x_a(t)\}, \quad (2.26)$$

onde, $[A(k)]$ é tomada como a matriz de coeficientes de influência aerodinâmica geral e q_∞ é a pressão dinâmica do escoamento livre.

2.1.3 Método de Solução de *Flutter*

Vários métodos são utilizáveis para a solução do problema de *flutter*, o qual resume-se a uma análise de estabilidade. Tipicamente, faz-se uso de formulações no domínio da frequência para pesquisar por valores críticos que levam à instabilidade aeroelástica. Dentre os principais métodos disponíveis tem-se os métodos P , K e $P-K$ (HODGES; PIERCE, 2002; ZAERO..., 2004; HASSIG, 1971). Todos esses métodos são desenvolvidos a partir da transformação das equações aeroelásticas para o domínio da variável de Laplace. Considerando um sistema aeroelástico genérico:

$$[M] \{\ddot{u}(t)\} + [K] \{u(t)\} = \{C_a\} \quad , \quad (2.27)$$

onde, $[M]$ é a matriz de massa, $[K]$ é a matriz de rigidez, $\{u(t)\}$ é o vetor dos deslocamentos e $\{C_a\}$ é o vetor de carregamentos aerodinâmicos.

Aplicando a transformada de Laplace (HODGES; PIERCE, 2002; ZAERO..., 2004), ob-

tém-se:

$$\left[s^2 [M] + [K] - q_\infty \left[A\left(\frac{sc}{V}\right) \right] \right] \{\bar{u}(s)\} = 0 \quad , \quad (2.28)$$

onde, s é a variável de Laplace, $[A]$ é a matriz de coeficientes de influência aerodinâmica geral, vista também na equação (2.26) e $\{\bar{u}(s)\}$ é o vetor de posições no domínio da variável de Laplace.

Tornando a variável de Laplace adimensional, ou seja, $p = \frac{sc}{V} = (\gamma k + ik)$, onde γ é a taxa de decaimento e k é a frequência reduzida, é possível chegar na equação:

$$\left[\left(\frac{V}{c}\right)^2 [M] p^2 + [K] - q_\infty [A(p)] \right] \{\bar{u}(p)\} = 0 \quad , \quad (2.29)$$

que é a equação para solução do problema aeroelástico utilizada pelo método P .

Para a obtenção da equação no domínio da frequência reduzida, substitui-se p por ik na equação (2.29). Se um termo de amortecimento artificial estrutural complexo, proporcional à rigidez, ig , for acrescentado obtém-se:

$$\left[-\omega^2 [M] + (1 + ig) [K] - q_\infty [A(ik)] \right] \{\bar{u}(ik)\} = 0 \quad . \quad (2.30)$$

Reescrevendo a expressão da pressão dinâmica, $q_\infty = \frac{1}{2}\rho V^2 = \frac{1}{2}\rho\left(\frac{\omega c}{k}\right)^2$, onde ρ é a densidade do ar, substituindo na equação (2.30) e dividindo-a por ω^2 , obtém-se:

$$\left[[M] + \frac{\rho}{2}\left(\frac{c}{k}\right)^2 [A(ik)] - \lambda_k [K] \right] \{\bar{u}(ik)\} = 0 \quad , \quad (2.31)$$

utilizada na solução do problema aeroelástico pelo método K , onde $\lambda_k = \frac{(1+ig)}{\omega^2}$ é seu auto-valor complexo.

O método K consiste em calcular os auto-valores do sistema aeroelástico para cada valor de frequência reduzida k escolhido. A frequência de *flutter*, ω_f , e as respectivas velocidade, V_{crit} , e amortecimento artificial, g , são dados por:

$$\omega_f = \frac{1}{\sqrt{Re(\lambda_k)}} \quad , \quad (2.32)$$

$$g = \omega_f^2 \text{Im}(\lambda_k) = \frac{\text{Im}(\lambda_k)}{\text{Re}(\lambda_k)} \quad , \quad (2.33)$$

$$V_{crit} = \frac{\omega_f c}{k} \quad . \quad (2.34)$$

O desenvolvimento do método P - K é semelhante ao do método K , mas se utiliza de uma formulação matematicamente inconsistente, uma vez que associa o auto-valor p a um movimento senoidal amortecido, enquanto a matriz $[A(ik)]$ é obtida a partir de um movimento harmônico simples não-amortecido (ZAERO..., 2004). Contudo, acredita-se que o método P - K produza melhores aproximações e que seja superior ao método K em diversos aspectos (HASSIG, 1971), exceto pela velocidade de *flutter* que é muito similar àquela prevista pelo método K , com o agravante de ser mais lento. A equação inicial para o método P - K é escrita como:

$$\left[\left(\frac{V}{c} \right)^2 [M] p^2 + [K] - q_\infty [A(ik)] \right] u = 0 \quad . \quad (2.35)$$

Uma matriz de amortecimento aerodinâmico é adicionada à equação (2.35), resultando:

$$\left[\left(\frac{V}{c} \right)^2 [M] p^2 + [K] - q_\infty \frac{[A^I]}{k} p - q_\infty [A^R] \right] u = 0 \quad , \quad (2.36)$$

onde $[A^R]$ e $[A^I]$ são as partes real e imaginária de $[A(ik)]$, respectivamente, ou seja:

$$[A(ik)] = [A^R] + i [A^I] \quad . \quad (2.37)$$

Substituindo $p = g + ik$, sendo $g = \gamma k$, no terceiro termo da equação (2.36), obtém-se:

$$\left[\left(\frac{V}{c} \right)^2 [M] p^2 + [K] - q_\infty \frac{[A^I]}{k} g - q_\infty [A(ik)] \right] u = 0 \quad , \quad (2.38)$$

que ao ser comparada à equação (2.35), facilmente se nota que o termo excedente:

$$-q_\infty \frac{[A^I]}{k} g \quad , \quad (2.39)$$

representa a matriz de amortecimento aerodinâmico adicionada.

A equação (2.38) é então resolvida para diversos valores de V e p associados aos modos

de interesse, num processo iterativo que ajusta o valor da frequência reduzida k ao valor da parte imaginária de p para cada modo estrutural.

Neste trabalho optou-se pela utilização do método K , por ter maior velocidade de execução computacional e previsão de velocidade muito similar à do $P-K$. O modelo segue os passos do método K para organizar os dados de velocidade, amortecimento e frequência obtidos. Como resultado é possível traçar os gráficos de amortecimento (g) e frequência (ω) *versus* velocidade (V), que tipicamente são conhecidos como curvas $V-g-f$ para análise de condições críticas para o *flutter*.

Durante uma solução deste tipo é comum ocorrer uma mistura entre as informações obtidas em termos de auto-valores (modos), de forma que se os dados forem utilizados diretamente para a plotagem, as curvas apresentarão incoerências. Para resolver este problema, Silva (1994) apresenta um procedimento de separação de modos que varre todas as curvas e compara os gradientes ponto a ponto. Assim, os valores são coerentemente trocados para que as curvas $V-g-f$ fiquem suaves e relacionem-se corretamente em termos dos respectivos modos aeroelásticos.

Após a separação de modos, é possível gerar os gráficos para cada um deles e pelas curvas de V contra g , como no exemplo da Figura 2.5, verificar em qual velocidade o amortecimento artificial torna-se zero. Para a obtenção do valor exato da velocidade é necessário fazer uma interpolação. Uma importante característica do método K , segundo Silva (1994), é que os valores de amortecimento durante a evolução modal não têm significado físico, a não ser na condição de estabilidade marginal ($g = 0$). Outra importante característica é o fato de haver um termo $\frac{1}{k}$ na equação do método K , o que impede o uso dos modos de corpo rígido ($k = 0$) na solução. Desta forma, impossibilita o seu uso na solução de problemas de divergência, outro importante fenômeno aeroelástico.

Figura 2.5: Exemplo de um gráfico V - g .

2.2 Metamodelos

Os metamodelos são substitutos de outros modelos, buscando em geral melhoras no custo computacional e são também conhecidos como *surrogate models*, do termo em inglês. Para sua utilização e posteriores comparações com os modelos originais, é necessário organizar as variáveis de entrada e saída exatamente da mesma maneira para todos eles. A Figura 2.6 ilustra as características do tipo de asa utilizada neste trabalho, onde se pode ver as variáveis geométricas, como a envergadura B e o ângulo de enflechamento do bordo de ataque Λ , algumas outras características, como as faixas aerodinâmicas, os elementos finitos e as massas concentradas sobre os nós dos elementos. O modelo aerodinâmico em termos de faixas junto aos nós da modelagem por elementos finitos da estrutura. A distribuição deve ser tal que cada nó do modelo MEF coincida com o centro de uma faixa

aerodinâmica, de modo que a contribuição de cada elemento para a previsão do *flutter* seja computada.

Figura 2.6: Características gerais do tipo de asa utilizado.

As variáveis que definem cada indivíduo e que são as entradas utilizadas neste trabalho estão ilustradas pela Figura 2.7. São elas os valores de rigidez EI e GJ para cada um dos elementos, bem como os parâmetros geométricos da asa: envergadura (B), área (S), ângulo de enflechamento (Λ) e afilamento (λ). As variáveis de saída dos metamodelos são a velocidade crítica de *flutter* (V_{crit}) e massa estrutural (M).

Figura 2.7: Variáveis de entrada e saída dos metamodelos.

A massa estrutural é calculada a partir dos valores das distribuições de rigidez,

efetuando-se uma integração numérica da área de seção transversal pela envergadura. Para isso criou-se uma regra para estimar a área da seção transversal a partir dos valores EI e GJ . Para uma seção retangular, como ilustra a Figura 2.8, os valores dos momentos polares de inércia I e J (torcional) são dados por,

$$I = \frac{b_r \cdot h_r^3}{12} , \quad (2.40)$$

$$J = \frac{b_r \cdot h_r^3}{12} + \frac{b_r^3 \cdot h_r}{12} , \quad (2.41)$$

e sua área é

$$A = b_r \cdot h_r , \quad (2.42)$$

onde b_r é a largura da seção transversal e h_r é a altura da mesma (ver Figura 2.8).

Figura 2.8: Seção transversal retangular de uma longarina simples.

Substituindo a área nas duas primeiras:

$$I = \frac{A \cdot h_r^2}{12} , \quad (2.43)$$

e

$$J = \frac{A}{12} \cdot (h_r^2 + b_r^2) . \quad (2.44)$$

Isolando o termo de área em ambas as equações, 2.43 e 2.44, tem-se,

$$A_I = \frac{12 \cdot I}{h_r^2} , \quad (2.45)$$

e

$$A_J = \frac{12 \cdot J}{(h_r^2 + b_r^2)} . \quad (2.46)$$

Finalmente, a área considerada é a média aritmética das duas descritas

$$A = \frac{A_I + A_J}{2} . \quad (2.47)$$

2.2.1 Metamodelagem via Rede Neural

Uma rede neural artificial é uma ferramenta matemática inspirada no cérebro dos animais, que têm a propriedade de adaptação ou aprendizado (HAGAN et al., 1996; HAYKIN, 1999). A RN sem realimentação (ou direta, em inglês, *feedforward*) é composta de unidades de processamento chamadas neurônios, semelhante aos neurônios de seres vivos. O modelo de neurônio mais usual é o perceptron, ilustrado na Figura 2.9. Neste modelo os sinais de entrada são multiplicados pelos pesos (também conhecidos como pesos sinápticos, assemelhando-se às sinapses de neurônios biológicos) que medem a importância das conexões da rede. Eles são somados e o resultado é comparado ao *bias* (ou *threshold*), criando o potencial de ativação. Sobre este é aplicada uma função de ativação, para finalmente ser alcançada a saída do neurônio. De acordo com a Figura 2.9, a saída pode ser descrita matematicamente como:

$$o_j = \varphi \left(\theta_j + \sum_{i=1}^n x_i \cdot w_{ij} \right) , \quad (2.48)$$

onde x_i é a i -ésima entrada da rede ($i = 1, 2, \dots, n$), w_{ij} descreve o valor do peso associado à conexão recebendo a i -ésima entrada no j -ésimo neurônio, o_j é a saída do j -ésimo neurônio, θ_j é o valor do *bias* para o j -ésimo neurônio e $\varphi ()$ é a função de ativação.

Geralmente, como função de ativação são utilizadas funções sigmóides, tais como a tangente hiperbólica,

$$\varphi(x) = \frac{2}{1 + e^{-2x}} - 1 . \quad (2.49)$$

A arquitetura direta de redes neurais (*cf.* Fig. 2.10) representa o padrão de conexão dos neurônios. Esta montagem característica as faz mais complexas, capazes de aprender mais informações. O treinamento de uma RN é o processo de aprendizado onde o conhe-

Figura 2.9: Modelo de neurônio artificial.

cimento é transmitido à ela. Neste processo os pesos sinápticos são ajustados para que forneçam os resultados esperados da rede quando variáveis de entrada são dadas. Existem diversos algoritmos de treinamento conhecidos, dentre os quais o de retro-propagação (em inglês, *back-propagation*) de Levenberg-Marquardt é um dos mais eficientes para redes multicamadas (HAGAN et al., 1996).

Figura 2.10: Exemplo de arquitetura direta multicamada.

Após ter sido treinado, um modelo de rede neural se adequa perfeitamente ao conceito de metamodelagem, conservando as características do sistema modelado em termos de uma função aproximada. Dentre as vantagens desta abordagem, a organização em paralelo de uma RN permite soluções onde múltiplas restrições devem ser satisfeitas simultaneamente. Além disso, a arquitetura de neurônios não-lineares distribuídos é responsável pela habilidade para trabalhar como substitutos de sistemas complexos não-lineares (PITT; HAUDRICH, 2004). Uma RN também tem vantagem sobre metodologias

de interpolação porque não sofre com restrições de convergência.

2.2.2 Metamodelagem via Interpolação por Funções de Base Radial

Uma função real cujo valor depende apenas da magnitude do seu argumento é denominada radial. Se $g(x) = \phi(\|x\|) = \phi(r)$, onde $\phi : [0, \infty) \rightarrow \mathbb{R}$ e r é o comprimento do vetor x , então, $\phi(r)$ é denominada uma *função de base radial* (do inglês, *radial basis function* – *RBF*) (BUHMANN, 2003). Isto significa que $\phi(r)$ é constante para vetores de entrada x de mesmo comprimento.

As escolhas clássicas para RBFs são:

- Linear:

$$\phi(r) = r \quad , \quad (2.50)$$

- Gaussiana:

$$\phi(r) = \exp\left(-\frac{r^2}{2\beta^2}\right) \quad , \quad \text{para todo } \beta > 0 \quad , \quad (2.51)$$

- Multi-quadrático:

$$\phi(r) = \sqrt{r^2 + \beta^2} \quad , \quad \text{para todo } \beta > 0 \quad , \quad (2.52)$$

- *Splines* poli-harmônicas:

$$\phi(r) = r^k, \quad k = 1, 3, 5, \dots \quad , \quad (2.53)$$

$$\phi(r) = r^k \ln(r), \quad k = 2, 4, 6, \dots \quad , \quad (2.54)$$

$$\phi(r) = r^2 \ln(r) \quad , \quad (2.55)$$

onde $r = \|x - x_i\|$ para $i = 1, 2, \dots, N$ e β é uma constante usada para ajustar a forma da RBF.

Interpolação via RBFs considera a aproximação $s(x)$, para uma função $f(x)$, ou seja,

$$s(x) \approx f(x) \quad , \quad (2.56)$$

como a combinação linear de N RBFs, de forma que:

$$s(x) = \sum_{i=1}^N w_i \phi(\|x - x_i\|) \quad , \quad (2.57)$$

onde w_i , para $i = 1, 2, \dots, N$, são fatores de peso.

Seja um conjunto de dados (x_i, f_i) , para $i = 1, 2, \dots, N$. A interpolação por RBFs implica em montar um sistema de equações lineares,

$$\sum_{i=1}^N w_i \phi(\|x_j - x_i\|) = f_j \quad , \text{ para } j = 1, 2, \dots, N \quad , \quad (2.58)$$

e resolver os respectivos fatores de peso w_i .

A Eq. (2.58) pode ser reescrita na forma matricial,

$$\begin{bmatrix} \phi(\|x_1 - x_1\|) & \phi(\|x_1 - x_2\|) & \cdots & \phi(\|x_1 - x_N\|) \\ \phi(\|x_2 - x_1\|) & \phi(\|x_2 - x_2\|) & \cdots & \phi(\|x_2 - x_N\|) \\ \vdots & \vdots & \ddots & \vdots \\ \phi(\|x_N - x_1\|) & \phi(\|x_N - x_2\|) & \cdots & \phi(\|x_N - x_N\|) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix} = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_N \end{bmatrix} \quad , \quad (2.59)$$

ou seja,

$$\mathbf{\Phi} \mathbf{w} = \mathbf{f} \quad . \quad (2.60)$$

Observa-se que o processo de interpolação requer $\mathbf{\Phi}$ inversível. De fato, prova-se que para RBFs, $\mathbf{\Phi}$ é sempre simétrica e inversível, mesmo para dados arbitrariamente espalhados (LIU, 2003). A existência de $\mathbf{\Phi}^{-1}$ é a maior vantagem do uso de RBFs para interpolação, quando comparado com métodos de interpolação polinomial.

Métodos de interpolação usando RBFs também podem incluir polinômios de ordem baixa, o que expande a aplicabilidade para conjunto de dados espalhados (LIU, 2003).

Desta forma, pode-se reescrever a equação (2.57) como,

$$s(x) = p(x) + \sum_{i=1}^N w_i \phi(\|x - x_i\|) \quad , \quad (2.61)$$

onde, $p(x)$ é um polinômio de ordem m descrito por,

$$p(x) = \sum_{j=0}^m \sum_{i=1}^N a_j x_i^j \quad . \quad (2.62)$$

Sendo definida a função a ser interpolada, os coeficientes das RBFs e do polinômio $p(x)$ na equação (2.61), podem ser obtidos do sistema linear aumentado:

$$\begin{bmatrix} \Phi & \mathbf{P} \\ \mathbf{P}^T & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{w} \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} \mathbf{f} \\ \mathbf{0} \end{bmatrix} \quad , \quad (2.63)$$

onde Φ , $\mathbf{w}$ e $\mathbf{f}$ são dadas como na equação (2.59), $\mathbf{P}$ é uma matriz formada por combinações de polinômios, tal que $p_j(\mathbf{x}_i)$, para $i = 1, 2, \dots, N$ e $j = 1, 2, \dots, m$ e $\mathbf{a}$ são os coeficientes do polinômio $p(x)$.

A rotina utilizada para metamodelagem foi baseada em uma rotina em Matlab[®] desenvolvida por Chirokov (2006). É baseada em uma função interpolante da forma,

$$s(x) = a_0 + a_1 x + \sum_{i=1}^N w_i \phi(\|x - x_i\|) \quad , \quad (2.64)$$

onde um polinômio de primeira ordem é incluído, resultando,

$$\mathbf{P} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_N \end{bmatrix} \quad , \quad \mathbf{a} = \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} \quad ,$$

quem compõem o sistema linear dado pela equação (2.63), sendo que Φ , $\mathbf{w}$ e $\mathbf{f}$ são dadas como na Eq. (2.59).

Os comandos principais dessa rotina são: `rbfcreate` – que calcula os coeficientes da interpolação a partir de dados apresentados; e `rbfinterp` – que utiliza os coeficientes

calculados para a interpolação.

2.2.3 Metamodelagem via Rede Neural por Funções de Base Radial

As redes neurais de funções de base radial (a partir daqui referida como RN RBF) são aquelas que apresentam neurônios modelados por RBFs. A idéia principal é baseada na integração dos princípios da interpolação via RBFs, conforme já exposto na Seção 2.2.2, com as vantagens do processo de treinamento sistemático pra obtenção das RNs. Uma RN RBF difere das abordagens de RN tradicionais nos seguintes aspectos: (i) ela é sempre uma rede com arquitetura de dupla camada direta, (ii) a primeira camada da rede é composta por RBFs como funções de ativação (neurônios RBF), (iii) a arquitetura da rede é definida pelo processo de treinamento, visto que o número de neurônios depende das dimensões do vetor de entradas, e (iv) a camada de saída é linear.

O pacote computacional Matlab[®] (<http://www.mathworks.com>) é utilizado para a produção de metamodelos de redes RBF. O pacote adota uma arquitetura convencional, como ilustrada na Figura 2.11, definido em termos de duas camadas intermediárias: a primeira de neurônios RBF (*radbas*) e a segunda de neurônios de função de ativação linear (*purelin*).

Figura 2.11: RN por RBF como implementado no Matlab[®] (<http://www.mathworks.com>).

Cada neurônio RBF da primeira camada da rede RBF recebe o valor da distância entre valores de peso e os elementos do vetor das entradas (obtido em $\| \mathbf{dist} \|$) e multiplicado pelo respectivo valor de *bias*. Tal valor de *bias* permite o ajuste da sensibilidade do neurônio RBF. Portanto, para R entradas na rede RBF, R valores de peso são usados. O resultado é, então, transformado pela função de ativação denominada *radbas*, dada por,

$$\phi(r) = e^{-r^2} , \quad (2.65)$$

e ilustrada na Figura 2.12.

Figura 2.12: Função de ativação RBF definida para o comando *radbas* (<http://www.math-works.com>).

As saídas de todos os neurônios RBF da primeira camada da rede são multiplicados por valores de peso, ao resultado é somado um valor de *bias*, que alimentam os T neurônios lineares convencionais (*purelin*), produzindo as saídas da rede RBF. Observar que na Figura 2.11 foi ilustrado apenas um único neurônio linear para obter a saída da rede RBF.

Para se obter a RN RBF final para um dado conjunto de dados o comando *newrb* pode ser utilizado. Aqui uma RN RBF é obtida apresentando o dados de entrada e saída e um parâmetro que ajusta o espalhamento associado à função de ativação RBF (no caso o parâmetro *spread*). O processo inicia-se com um número pequeno de neurônios RBF na primeira camada e o sistema de equações lineares para a solução dos pesos e *bias* são determinados. Esse passo se repete acrescentando-se neurônios RBF até que se alcance a meta de erro ou o número máximo de neurônios RBFs. Observa-se da teoria de interpolação via RBF que o número de neurônios na RN RBF não ultrapassa o número de elementos do vetor de entradas.

O parâmetro **spread** tem grande relevância no processo, pois permite definir os limites de abrangência das funções de ativação RBF. Esse vincula a cada **bias** na primeira camada da rede ao um valor $0,833/\text{spread}$ (*spread*, que em inglês significa espalhamento, é um parâmetro para ajustar a forma da função RBF). Com isso, supondo o valor de **spread** como sendo 4, então cada neurônio RBF responderá com no mínimo $\phi(r) = a = 0,5$ (ver Figura 2.12 e Eq. (2.65)) para qualquer vetor de entrada dentro de uma distância 4. Recomenda-se que o valor de **spread** seja suficientemente grande para que os neurônios respondam no espaço de abrangência do vetor de entradas.

Organização do Processo de MDO

O processo de MDO é esquematizado como descrito a seguir. As variáveis de projeto e as restrições são definidas pelo usuário. Com as distribuições de rigidez flexional e torcional, aliadas à geometria, é possível desenvolver uma análise numérica estrutural, de modo a se obter as características modais. Informações adicionais de massas não estruturais sobre a asa, representando corpos externos como tanques de ponta de asa, motores, *Pods*, armamentos, e mesmo o revestimento da asa são considerados como massas e momentos de inércia concentrados. Neste ponto, a massa estrutural já pode ser estimada. Após a análise dinâmico-estrutural, com informações adicionais de aerodinâmica, a solução aeroelástica para o *flutter* pode ser realizada. O AG é responsável pela criação da população inicial e usa os resultados obtidos pelos modelos de avaliação para qualificar e dar prosseguimento à evolução da população. A Figura 3.1 ilustra as organizações do MDO, onde se mostra claramente que o metamodelo efetua as tarefas que todos os modelos numéricos necessários para a solução aeroelástica fariam.

3.1 Otimização por Algoritmo Genético

AGs (GOLDBERG, 1989) são um tipo de algoritmo de busca baseado nas teorias de genética, evolução e seleção natural das espécies de Charles Darwin, que manipula conjuntos de possíveis soluções codificadas para um problema. Esta abordagem é bas-

Figura 3.1: Esquemas de MDO completo e baseado em metamodelo.

tante popular no campo da otimização, particularmente em práticas de MDO, por serem mais aptas para domínios de soluções muito grandes que os métodos de busca exaustiva (MICHALEWICZ, 1994).

Algumas diferenças básicas entre os métodos de otimização mais comuns e os algoritmos genéticos, apresentadas por Goldberg (1989), podem ser citadas: *(i)* AGs não trabalham com os parâmetros de otimização em si, mas com uma codificação destes; *(ii)* AGs não procuram um único ponto, mas sim uma população de pontos; *(iii)* AGs utilizam informações de funções objetivo e não derivadas ou outros conhecimentos adicionais; e *(iv)* AGs utilizam regras de transição probabilísticas e não determinísticas.

Um AG para otimização de sistemas tem o funcionamento simples e utiliza operações triviais com vetores, cujos termos descrevem as características das possíveis soluções para o problema em estudo. O processo se inicia com a criação de um conjunto de soluções, comumente chamado de população inicial. Tais soluções (indivíduos) são descritos pelos já mencionados vetores, os quais são denominados cromossomos, por conterem em seus termos (*bits*) as variáveis a serem trabalhadas pela otimização. Esses elementos são manipulados de maneira semelhante aos processos de seleção e evolução observados na natureza, com operadores inspirados em genética biológica como cruzamentos (em inglês, *crossover*) onde os mais aptos têm maior chance de participação, mutações genéticas,

entre outros.

A terminologia típica utilizada com os AGs inclui termos que definem os elementos, baseados nos termos utilizados em genética, dos quais se pode destacar:

População: um conjunto de indivíduos que representam soluções para problema tratado;

Indivíduo: um membro da população, descrito através de um cromossomo;

Cromossomo: um código que descreve as características de cada indivíduo, sendo cada uma destas relacionadas a um gene. Também pode ser chamado de genótipo;

Gene: trecho de um cromossomo ligado a uma herança genética (uma característica) do indivíduo;

Função de Aptidão: também chamada de função de *fitness*, a função de aptidão é conhecida como função de custo no jargão de otimização. Ela define o quanto o indivíduo é apto para sobreviver no meio em que vive.

3.1.1 Operadores dos Algoritmos Genéticos

Operadores baseados nos processos naturais da genética dos seres vivos são utilizados na maioria dos AGs, embora seja possível criar operadores para atender peculiaridades das aplicações de AGs. O mais simples de todos os operadores é a reprodução, que consiste na cópia de indivíduos (cromossomos) de acordo com seus valores da função de aptidão. Como a função de aptidão representa quão boa é a solução, na reprodução, os indivíduos com maiores aptidões terão maior probabilidade de contribuir geneticamente nas gerações seguintes. A reprodução é, então, uma versão artificial da seleção natural das espécies de Darwin, onde os mais aptos tendem a permanecer e os menos aptos tendem a sumir ao longo das gerações.

A maneira mais comum de se implementar computacionalmente a reprodução é através da chamada roda de roleta (GOLDBERG, 1989), que conceitualmente funciona como as

rodas de roleta de cassinos. Os indivíduos pais são colocados em fatias na roda, para que esta, quando girada, pare em uma posição qualquer e defina qual será o pai escolhido. Na roda, o tamanho da fatia ocupada por cada indivíduo é proporcional ao seu valor para a função de aptidão, definindo assim a probabilidade dos indivíduos de serem escolhidos como progenitores das próximas gerações. Para a melhor compreensão do conceito descrito, a Figura 3.2 (GOLDBERG, 1989) mostra um exemplo de roda de roleta para uma população de quatro indivíduos.

Figura 3.2: Roda de roleta (GOLDBERG, 1989).

Um dos principais operadores do algoritmo genético é o cruzamento (*crossover*). Ele é o responsável por transmitir aos filhos características dos pais, uma vez que divide os cromossomos dos pais e troca partes destes, gerando assim novos cromossomos para os filhos. A Figura 3.3 ilustra o conceito deste operador. A seleção dos pais é feita através da roda de roleta, descrita anteriormente e o local (ou os locais) de quebra para a troca das partes dos cromossomos é escolhido aleatoriamente. Esse procedimento é utilizado somente para casos que utilizam codificação binária dos cromossomos. Nos casos de cromossomos reais, outros métodos são utilizados para realizar os cruzamentos. Um deles, utilizado neste trabalho, é feito como uma recombinação linear dos termos dos vetores (cromossomos) da seguinte maneira: sejam P_{1c} e P_{2c} dois indivíduos escolhidos

Figura 3.3: *Crossover* - Pais e filhos gerados.

para cruzamento e seja a_c um coeficiente real aleatório com valor entre 0 e 1. Os filhos F_1 e F_2 são gerados com a recombinação:

$$\begin{aligned} F_1 &= a_c P_{1c} + (1 - a_c) P_{2c} \\ F_2 &= (1 - a_c) P_{1c} + a_c P_{2c} \end{aligned} \quad (3.1)$$

Outro importante operador é a mutação, responsável pela diversificação da população, permitindo que se trabalhe com indivíduos de áreas distintas do domínio de soluções, tornando o algoritmo genético um método de otimização robusto. Sob outro ponto de vista, pode-se dizer que ao longo do processo de otimização pode-se perder material genético útil para a aptidão dos indivíduos e a mutação é aplicada para que essa perda irreparável não ocorra. O funcionamento da mutação é bem simples, consistindo na eventual substituição do valor de uma parte do gene, um 0 por 1, ou 1 por 0 dentro de um cromossomo binário, por exemplo. No caso de cromossomos reais outras estratégias devem ser utilizadas para alterar o valor original de cada bit do cromossomo, também conforme sua probabilidade de mutar.

Durante a evolução das gerações, bons indivíduos podem gerar filhos piores que eles mesmos, e assim, a nova geração pode deixar de herdar suas boas características. Ou seja, pela simples geração de filhos através dos operadores descritos anteriormente, não é garantido que os melhores indivíduos já encontrados permanecerão nas gerações futuras. É necessária então a inclusão de um novo operador, chamado elitismo, que tem a função de

manter os melhores indivíduos ao longo das sucessivas gerações. O número de indivíduos pertencentes ao grupo do elitismo é mais uma variável dentre os parâmetros do AG. Estudos realizados na universidade de Michigan (DE JONG, 1975) comprovam que o elitismo melhora o desempenho do algoritmo genético, embora em certos casos pode prejudicar a evolução da população, dependendo do domínio de soluções utilizado, conduzindo a otimização a ótimos locais.

3.1.2 Funcionamento de um AG Básico

Segue uma síntese dos precedimentos comuns de um AG simples, conforme o exemplo de Goldberg (1989). A otimização por AG parte de uma população inicial de soluções do problema proposto, as quais são codificadas como cromossomos (geralmente vetores de números binários), que descrevem as características do sistema. O processo segue baseado em operações probabilísticas que lembram as etapas típicas na reprodução e evolução de seres vivos na natureza, sejam elas a seleção, a reprodução e os cruzamentos entre os indivíduos para a criação de filhos. Como resultado, os filhos ou novos indivíduos da população, têm em seus cromossomos as características genéticas de seus pais, que serão transmitidas para as futuras gerações (iterações) do AG. Existe a possibilidade de ocorrer mutações nos genes dos cromossomos, dentro de uma probabilidade definida previamente. No decorrer das gerações, os indivíduos mais aptos a sobreviverem, ou seja, as melhores soluções, permanecerão na população, enquanto os menos aptos (as piores soluções) serão descartados. Esse tipo de processo de seleção é geralmente realizado por operadores específicos. A Figura 3.4 ilustra a sequência de um AG simples.

Uma rodada de evolução (de uma geração para outra) em uma população corresponde a uma busca no espaço de possíveis soluções (MICHALEWICZ, 1994), sendo necessário um balanço entre dois objetivos aparentemente conflitantes: (i) obter as melhores soluções e (ii) explorar o espaço de busca. Alguns métodos, como o *hillclimbing*, são muito eficazes em obter melhores soluções rapidamente, porém são pouco cautelosos com a exploração do espaço. Outros métodos de otimização trabalham justamente de modo contrário, como

Figura 3.4: Diagrama de blocos de um AG básico (CAIXETA JR., 2006).

os de busca aleatória. Os AGs pertencem a uma categoria de métodos de busca que conseguem um surpreendente equilíbrio entre estes dois objetivos.

3.2 Otimização Multiobjetivo

As implementações de AGs geralmente partem de códigos baseados no AG simples apresentado por Goldberg (1989), para serem posteriormente aprimorados em diversos aspectos, o que pode ser justificado pela sua facilidade de implementação e modificação, visto que é um algoritmo modular. Com isto, diversas modificações e avanços foram realizados, como utilização de cromossomos reais (ao invés de binários), mutações em mais de um grau (fortes e fracas, para momentos diferentes da evolução), entre inúmeras já apresentadas.

Existem situações em que não é possível combinar os diversos critérios de otimização

em uma única função objetivo, o que é a abordagem típica para otimização para objetivo único (em inglês, *single objective optimization*). Nestes casos o problema de otimização é denominado multiobjetivo ou multicritério. E uma vez que não se consegue relacionar estes critérios diferentes é necessário trabalhar com outras definições de otimalidade. O conceito de otimalidade de Pareto é um dos mais adotados para lidar com problemas de otimização multiobjetivo utilizando AGs. Este conceito, que tem suas bases lançadas nos trabalhos realizados por Vilfredo Pareto por volta do ano de 1900, um dos quais apresentado em Pareto (1906), define que as soluções ótimas de Pareto, ou a fronteira de Pareto, são aquelas que não podem ter um critério melhorado sem piorar ao menos um outro critério. Este tipo de comparação entre soluções é também a definição do conceito de dominância, pelo qual uma solução A domina outra solução B se de n critérios de otimização, para um deles A for melhor que B e para todos os $n - 1$ restantes A for melhor ou igual a B . Assim, se A dominar todas as soluções de um grupo, se diz que A é solução não-dominada (em inglês, *nondominated solution*).

O grupo liderado pelo professor indiano Kalyanmoy Deb desenvolveu códigos de AG que utilizam o conceito de dominância (ou não-dominância) para fazer a análise de aptidões dos indivíduos e posterior seleção para cruzamentos. O código ficou conhecido como NSGA-II (DEB et al., 2000), sigla que vem do nome em inglês *Non-dominated Sorting Genetic Algorithm*, sucessor do NSGA, desenvolvido anteriormente pelo mesmo grupo.

O AG implementado neste trabalho foi baseado inicialmente no AG simples de Goldberg (1989) e modificado para conter conceitos multiobjetivo semelhantes aos do NSGA-II. Por esta razão, será apresentada uma breve explanação da sequência de passos para a ordenação e atribuição de aptidão por não-dominância de uma população, conforme visto em detalhes no trabalho de Deb (2001). Ao fim do processo, a população estará separada em fronteiras de não-dominância e da melhor pra pior fronteira seus indivíduos receberão um valor de aptidão. É importante notar que dentro de uma mesma fronteira é considerada a distância entre as soluções, de forma a valorizar soluções mais distantes das outras, para obter um preenchimento mais homogêneo das fronteiras futuras.

Passo 1: O procedimento é iniciado com a escolha de um parâmetro de compartilhamento σ_{share} e de um número positivo e pequeno ϵ , para então inicializar o valor de aptidão mínimo $F_{min} = N_p + \epsilon$, onde N_p é o número de indivíduos na população. Neste ponto é definido o contador $j = 1$;

Passo 2: Classifica-se toda a população P de acordo com a não-dominância: $(P_1, P_2, P_3, \dots, P_{\rho_n})$, onde ρ_n é o número de fronteiras de não-dominância na população;

Passo 3: Para cada indivíduo q , $q \in P_j$:

Passo 3a: Atribuir o valor de aptidão $F_j^{(q)} = F_{min} - \epsilon$;

Passo 3b: Calcular o contador de nicho nc_q (detalhes deste cálculo serão mostrados adiante);

Passo 3c: Calcular a aptidão compartilhada $F_j'^{(q)} = \frac{F_j^{(q)}}{nc_q}$;

Passo 4: Redefine-se o valor mínimo de aptidão $F_{min} = \min(F_j'^{(q)} : q \in P_j)$, bem como $j = j + 1$;

Passo 5: Se $j \leq \rho_n$, volta-se ao Passo 3, senão o processo está concluído.

O cálculo do contador de nicho nc_q inicia-se com a definição de:

$$\sigma_{share} = \frac{\sqrt{\sum_{k=1}^n \left(x_k^{(u)} - x_k^{(l)}\right)^2}}{2 \sqrt[n]{q}} \quad , \quad (3.2)$$

onde (u) e (l) representam respectivamente os limites superior e inferior de cada k -ésimo objetivo da otimização, n é o número total de objetivos e q é o número de nichos igualmente espaçados no espaço de busca. Para o caso em que os cálculos de distância são normalizados, como em:

$$d_{ij} = \sqrt{\sum_{k=1}^n \left[\frac{x_k^{(i)} - x_k^{(j)}}{x_k^{(u)} - x_k^{(l)}} \right]^2} \quad , \quad (3.3)$$

o seguinte parâmetro de compartilhamento normalizado pode ser empregado:

$$\sigma_{share} = \frac{0,5}{\sqrt[n]{q}} \quad . \quad (3.4)$$

Segundo Deb (2001), quando o número de nichos (ou ótimos) q não é conhecido a priori, pode-se experimentar valores entre 5 e 10.

Tendo σ_{share} e d_{ij} definidos, passa-se ao cálculo da função S_h , chamada de função de compartilhamento, definida por:

$$S_h(d) = \begin{cases} 1 - \left(\frac{d}{\sigma_{share}}\right)^{\alpha_a} & , \text{ se } d \leq \sigma_{share}, \\ 0 & , \text{ para os outros casos.} \end{cases} \quad (3.5)$$

O significado desta função é que para $d \geq \sigma_{share}$, ou seja, distâncias iguais ou maiores que o parâmetro de compartilhamento, $S_h(d) = 0$, que implica que soluções que distam no mínimo σ_{share} entre si não têm efeito de compartilhamento umas sobre as outras. Já soluções com distâncias menores entre si terão o efeito aplicado. Se $\alpha_a = 1$, este efeito se reduz linearmente de 1 até 0, mas ele pode assumir outros valores. Fica claro então que em uma população, uma solução pode não sofrer efeitos de compartilhamento de algumas soluções, sofrer efeitos parciais de algumas outras e efeito total sobre si mesmo (para o caso de soluções que se repetem, gêmeos).

Finalmente, o cálculo do contador de nicho nc_q para a i -ésima solução (ou nc_i) é feito pela equação:

$$nc_i = \sum_{j=1}^{N_f} S_h(d_{ij}) \quad , \quad (3.6)$$

onde N_f é o número de soluções na fronteira de não-dominância, incluindo nesta conta o próprio valor (no caso i).

Resultados

As seções seguintes apresentam resultados da criação do banco de dados, dos estudos com os três metamodelos, do desempenho do AG, bem como de dois estudos de caso propostos para avaliação do funcionamento completo do MDO com metamodelo escolhido.

4.1 Banco de Dados

McKay et al. (1979) foram os primeiros a descrever a técnica de amostragem por hipercubo latino, que é um método estatístico que distribui amostras pelas dimensões de um vetor multidimensional, de forma a não repetir valores para cada uma das variáveis. Para exemplificar este conceito, uma malha quadrada é um “Quadrado Latino” (um Hipercubo Latino 2D) se, e somente se, existe apenas uma amostra em cada linha e em cada coluna, conforme ilustra a Figura 4.1. O LHS é uma generalização deste conceito para um problema N -dimensional. Para criar uma distribuição de M amostras com N variáveis, o LHS utiliza M divisões para cada uma das N variáveis. Os números de amostras e variáveis são independentes entre si, uma das grandes vantagens do LHS.

O processo de criação do banco de dados compreende os arranjos das variáveis usadas para descrever cada indivíduo, que são os coeficientes de rigidezes flexional e torcional, EI e GJ , em 8 posições ao longo da envergadura da asa (veja a Figura 2.6), a envergadura da asa, b , a área em planta da asa, S , o ângulo de enflechamento do bordo de ataque, Λ ,

X			
	X		
			X
		X	

Figura 4.1: Exemplo de LHS 2D.

e o afilamento da asa, λ , resultando em um total de 20 variáveis. As faixas de trabalho para cada variável foram escolhidas a partir de diversas avaliações, de modo a permitir que a faixa de valores das velocidades críticas de *flutter* estivesse limitada em uma onde a solução aeroelástica é considerada confiável, com comportamento bastante aceitável. Por outro lado, estes valores são baseados em aeronaves com características de vôo de grande altitude e grande autonomia (HALE), embora eles sejam apenas supostos e não comparados com qualquer projeto em particular.

Tabela 4.1: Faixas de trabalho das variáveis.			
Variável	Valor mín.	Valor máx.	Unidade
EI_1	90.000	110.000	Nm^2
EI_8	70.000	—	Nm^2
GJ_1	90.000	110.000	Nm^2
GJ_8	70.000	—	Nm^2
b	20	21,5	m
S	21	22	m^2
Λ	0	3	<i>graus</i>
λ	0,7	1	—

A Tabela 4.1 apresenta as faixas de trabalho para as variáveis, onde os valores de rigidez à flexão e à torção são definidos sob contornos definidos, de modo a permitir distribuições coerentes de rigidez ao longo da envergadura, com seus valores diminuindo da raiz em direção à ponta da asa. Para isto, os valores de rigidez são definidos ordenadamente, da raiz para a ponta da asa (da seção 1 até a 8, na Fig.4.2). O valor para a primeira

seção, na raiz, varia entre 90.000 Nm^2 e 110.000 Nm^2 , conforme ilustra o retângulo na Fig.4.2, enquanto os valores subsequentes variam de 70.000 Nm^2 até o valor definido para a seção adjacente anterior. Por exemplo, o valor de EI da primeira seção, EI_1 , é definido dentro do intervalo mostrado na Tabela 4.1. Para a segunda seção, EI_2 , a faixa é definida de 70.000 Nm^2 à EI_1 , continuando sucessivamente este processo até a oitava seção. O critério é o mesmo para ambos valores de rigidez à flexão e à torção.

Figura 4.2: Exemplo de distribuição de rigidez ao longo da semi-envergadura da asa.

As massas concentradas sobre os nós de cada elemento finito (vide Fig. 2.6) não variam no processo de otimização, pois os valores de sua variação seriam pequenos, dadas as faixas de trabalho das variáveis geométricas. Para todos os estudos de escolha dos metamodelos e de desempenho do AG que se seguem, os valores dessas massas são definidos como 140 kg de massa e 100 kgm^2 de momento de inércia para a massa central, que representa a fuselagem da aeronave e para todas as outras distribuídas sobre as asas, 5 kg de massa e $4,5 \text{ kgm}^2$ de momento de inércia, representando o revestimento da asa, não considerado como estrutural, para simplificar a modelagem, além de outras massas não estruturais.

A faixa de valores de velocidade de *flutter* também foi verificada por meio de diversas combinações de variáveis de entrada. Da Tabela 4.1 foram selecionados apenas os valores mínimos e máximos de cada variável, possibilitando 64 arranjos diferentes nestes

contornos. Ao invés de se utilizar um valor mínimo ou máximo de rigidezes para cada uma das 8 seções da asa, dois padrões de distribuição de rigidez foram definidos como máximo e mínimo, respectivamente descritos como uma distribuição constante com valor de 110.000 Nm^2 e uma distribuição com decaimento exponencial, partindo do valor de 90.000 Nm^2 na raiz da asa, até um valor de 70.000 Nm^2 na ponta da asa. Cada combinação foi avaliada para se obter os parâmetros de *flutter*, que são a velocidade e a frequência.

O resultado desta avaliação revelou um valor mínimo de $50,95 \text{ m/s}$ para a velocidade crítica de *flutter*, enquanto o valor máximo computado foi de $108,49 \text{ m/s}$. O valor médio da velocidade de *flutter* foi de $65,25 \text{ m/s}$ com desvio padrão de $10,90 \text{ m/s}$. Além disso, as frequências de *flutter* foram encontradas na faixa de $2,87 \text{ Hz}$ até $3,64 \text{ Hz}$ com média de $3,26 \text{ Hz}$ e desvio padrão de $0,22 \text{ Hz}$. Estas soluções permitem inferir que o mecanismo de *flutter* é o mesmo para todo o domínio de soluções, uma vez que a faixa de frequências é particularmente estreita mesmo com uma variação relativamente grande de parâmetros.

Para as metamodelagens, dois bancos são utilizados, um para a preparação dos metamodelos (chamado de Banco de Preparação, para melhor compreensão) e outro para avaliação dos metamodelos (Banco de Teste). Para o Banco de Preparação, 1000 amostras foram criadas utilizando um LHS e avaliadas pelo código de solução aeroelástica. Para as análises estatísticas subsequentes dos metamodelos ajustados, o Banco de Teste foi produzido com 1500 amostras, seguindo os mesmos procedimentos e considerações anteriores.

4.2 Escolha do Metamodelo para o MDO

Nesta seção se mostra os detalhes de implementação dos três metamodelos escolhidos, para o problema de previsão de *flutter*, suas qualidades e desempenho para este caso específico, bem como dados estatísticos que justificam a escolha de um deles para utilização no MDO proposto. Ressalta-se que para simplificação dos estudos a única variável de saída utilizada foi a velocidade crítica de *flutter*, V_{crit} , uma vez que a massa estrutu-

ral, das experiências anteriores, nunca apresenta problemas para os metamodelos, sendo facilmente assimilada, ou interpolada.

4.2.1 Metamodelo RN

Conforme descrito anteriormente, o algoritmo de *backpropagation* (ou retropropagação) de Levenberg-Marquardt (HAGAN et al., 1996) foi aplicado no treinamento da RN, lançando mão do Banco de Preparação. Após exaustivos testes com diferentes arquiteturas de RNs, foi escolhida uma arquitetura 20-40-2, com 2 camadas ocultas com funções de ativação sigmoidais (*cf.* Eq. (2.49)) e uma camada de saída com ativação linear. O treinamento típico foi executado e os critérios de parada eram o alcance de erro nulo, ou número máximo de falhas nos cheques de validação igual a 225 ou número máximo de épocas igual a 3000. Estes valores foram escolhidos baseados em experiência prévia de utilização do metamodelo, não se levando em conta nenhuma análise mais criteriosa. A Figura 4.3 ilustra o decaimento dos somatórios de erros médios quadráticos (SEM) para cinco treinamentos com conjuntos de pesos iniciais diferentes (preparados aleatoriamente). Ela demonstra estatisticamente que o método conduz a redes neurais com faixas de erro similares. Além disso, na Fig. 4.4 são apresentadas as saídas das cinco RNs, através de dados de treinamento e validação cruzada (aqui uma porção de 20% do Banco de Preparação é utilizada para validação cruzada em todos os casos considerados), demonstrando que o metamodelo RN provê um ajuste adequado ao problema.

A qualidade da RN para prever velocidades de *flutter* para soluções não utilizadas no treinamento foi checada com o Banco de Teste. A Figura 4.5 mostra os resultados comparativos da generalização pelo metamodelo RN com os obtidos pelo modelo de previsão aeroelástica, estes mostrados na figura como Objetivo. Estes resultados demonstram a boa capacidade de generalização do metamodelo RN, de onde se obteve um erro médio de 0,15% e um desvio padrão de 0,23% para V_{crit} . As linhas traço-ponto na Figura 4.5 delineam erros de 5% em V_{crit} enquanto as linhas tracejadas demarcam erros de 10%. Todos resultados das análises estatísticas estão listados na Tabela 4.2.

Figura 4.3: Desempenho do treinamento de metamodelos RN (SEM).

4.2.2 Metamodelo Interpolação por RBF

A Interpolação por RBF foi feita com a utilização da RBF Gaussiana, tal como

$$\phi(r) = \exp\left(-\frac{r^2}{2\beta^2}\right) \quad , \text{ para algum } \beta > 0, \beta \in \mathfrak{R} \quad , \quad (4.1)$$

onde $r = \|\mathbf{x} - \mathbf{x}_i\|$ para $i = 1, 2, \dots, N$ e β é uma constante real usada para ajustar a forma da RBF. Foi escolhido um valor de $\beta = 0,05$ como constante para RBF (também chamado de espalhamento), após testes com diversos valores. Os resultados deste metamodelo estão apresentados na Fig. 4.6, onde novamente as linhas traço-ponto são de 5% de erro e as tracejadas marcam 10% de erro em V_{crit} . Esta metamodelagem é aceitável na faixa de velocidades de 57 m/s até aproximadamente 73 m/s , porém fora deste intervalo a qualidade dos resultados decai consideravelmente. Mesmo com este comportamento, os resultados da estatística com o Banco de Teste são razoáveis, tendo erro médio de $1,78\%$ e desvio padrão de $1,70\%$ (*cf.* Tab. 4.2). Uma causa para tal comportamento pode ser pela escolha da RBF do tipo gaussiana, mas continuar explorando todas possíveis

Figura 4.4: Resultados dos treinamentos: Metamodelo RN *versus* modelo aerolástico (objetivo) – V_{crit} [m/s] nos dois eixos.

combinações de RBF foge do escopo deste trabalho. Outra possibilidade é ter o Banco de Preparação inadequado para este tipo de metamodelo. Uma maneira para checar isto seria a avaliação do metamodelo com bancos criados por outras técnicas, diferentes do LHS, mas novamente, isso não está dentro do escopo deste trabalho.

4.2.3 Metamodelo RN por RBF

Os parâmetros considerados para a implementação desta RN RBF incluem um espalhamento de 50 para a RBF e um número máximo de neurônios permitidos de serem adicionados de 2000, valores escolhidos após verificações com diversas combinações de parâmetros de treinamento. A Figura 4.7 apresenta como o erro médio e o desvio padrão

Figura 4.5: Resultados da avaliação estatística da RN (V_{crit} [m/s] nos dois eixos).

variam para metamodelos RN RBF determinados aleatoriamente. Estes resultados confirmam que o valor de β de 50 produz a menor soma de erros médios durante o treinamento das RN RBF, reforçando o motivo por sua escolha.

A rede resultante após o treinamento tem 784 neurônios na camada com função de ativação por RBF e a generalização realizada para a análise com o Banco de Teste é apresentada na Fig. 4.8, onde mais uma vez as linhas traço-ponto marcam 5% de erro e as tracejadas 10% de erro em V_{crit} . O desempenho deste metamodelo é ligeiramente melhor que o da Interpolação por RBF, apresentando erro médio de 1,09% e desvio padrão de 1,75%, embora ainda seja pior que o da RN pura.

Figura 4.6: Resultados da avaliação estatística da Interpolação por RBF (V_{crit} [m/s] nos dois eixos).

4.2.4 Metamodelo Escolhido

Os resultados de todas as análises estatísticas realizadas estão sintetizados na Tab. 4.2. Estes dados demonstram que os três metamodelos escolhidos têm potencial para aplicações de previsão de *flutter*, sendo esta uma das propostas de contribuição deste trabalho. Pelos resultados, fica evidente a superioridade do metamodelo RN. Assim, após observações destes valores tabelados, bem como das Figs. 4.5, 4.6 e 4.8, conclui-se que o metamodelo RN é o melhor ajustado para o problema aeroelástico formulado neste trabalho. Isto corrobora com a afirmação de Pitt e Haudrich (2004) de que a RN é hábil para lidar com sistemas complexos não-lineares.

Escolhido o metamodelo, resta a sua preparação para aplicação no ambiente de MDO,

Figura 4.7: Desempenho do metamodelo RN RBF para vários valores de β .

Figura 4.8: Resultados da avaliação estatística da RN RBF (V_{crit} [m/s] nos dois eixos).

uma vez que para esta aplicação o metamodelo deve ter como saída, além da velocidade crítica de *flutter*, a massa estrutural. Isto foi feito utilizando o mesmo banco de dados

Tabela 4.2: Análises estatísticas dos metamodelos com o Banco de Teste.

Metamodelo	Erro méd. [%]	Desv. Padrão [%]
RN	0,15	0,23
Interp. RBF	1,78	1,70
RN RBF	1,09	1,75

(Banco de Preparação), porém ao invés de se treinar uma rede 20-40-1, empregou-se uma rede 20-40-2. O treinamento desta rede também resultou em um metamodelo com boa capacidade de generalização para as duas variáveis de saída, conforme ilustra a Figura 4.9, com os resultados para as avaliações do Banco de Teste para a velocidade de *flutter*. Nesta figura também é possível notar que dos casos avaliados, raros apresentam velocidade acima de 85 m/s , motivo pelo qual será criada uma restrição no código de otimização para não admitir soluções acima desta velocidade. A Figura 4.10 mostra os resultados da análise estatística para a generalização da massa estrutural M , enquanto a Tabela 4.3 resume os erros médios e desvios padrão para ambas análises. Estes resultados, onde o maior erro médio é de 0,44% e o maior desvio padrão de 0,48%, permitem concluir que o metamodelo atende as expectativas para utilização no sistema de MDO. Pela Figura 4.10 também se evidencia o que foi dito anteriormente a respeito da facilidade de assimilação das redes neurais para a previsão de massa estrutural.

Tabela 4.3: Análises estatísticas do metamodelo RN escolhido.

Saída	Erro médio [%]	Desvio Padrão [%]
V_{crit}	0,44	0,48
M	0,04	0,04

4.3 Desempenho do AG

Os AGs trabalham considerando alguns parâmetros que devem ser escolhidos para determinar seu funcionamento. Destes, pode-se destacar a probabilidade de mutação, o número máximo de gerações da otimização (quando não existe um critério de parada definido), o número de indivíduos que participam do elitismo e o número de indivíduos na população. De experiências anteriores (CAIXETA JR., 2006; CAIXETA JR. et al., 2008;

Figura 4.9: Generalizações do Banco de Teste para V_{crit} .

CAIXETA JR.; MARQUES, 2009a, 2009b, 2010) conclui-se que uma população de 50 indivíduos fornece boa evolução e variabilidade à otimização, portanto este parâmetro é considerado definido com este valor. Para escolha dos outros parâmetros serão apresentados os resultados de 25 análises realizadas para avaliação do comportamento da otimização com a variação dos parâmetros. Cinco valores foram escolhidos para cada um de dois dos parâmetros (probabilidade de mutação e número de participantes do elitismo), totalizando os 25 casos avaliados, todos eles experimentados ao longo de 500 gerações, partindo da mesma população inicial. São eles: 10%, 20%, 30%, 40% e 50% para a probabilidade de mutação, 10, 20, 30, 40 e 50 indivíduos para tomar parte no elitismo. Uma vez escolhidos estes dois parâmetros, outros testes serão realizados para determinar o número de gerações que tende a conduzir a ótimos globais.

Os resultados são apresentados em termos de gráficos de velocidade de *flutter* - V_{crit}

Figura 4.10: Generalizações do Banco de Teste para M .

versus massa estrutural - M , onde os valores representam a fronteira de soluções não dominadas obtidas após a otimização com os parâmetros avaliados. Entre as características a serem avaliadas, algumas serão ressaltadas para possibilitar uma apreciação enriquecedora dos resultados. A homogeneidade da distribuição dos indivíduos nas fronteiras é uma característica interessante para que o conjunto de soluções apresente uma gama de resultados maior, ou seja, quanto menos aglutinadas as soluções, melhor a qualidade da otimização. A extensão da fronteira é outro aspecto que deve ser considerado, também para aumentar a gama de resultados, de maneira que distâncias maiores entre os valores mínimo e máximo apresentados para cada variável são mais desejáveis. Finalmente, a tendência de aproximação da fronteira em direção ao canto direito inferior dos gráficos mostra a busca por maiores velocidades e menores massas estruturais, sendo esta uma

qualidade requerida para a otimização.

A Figura 4.11 apresenta resultados dos cinco primeiros casos de otimização, com elitismo variando de 10 à 50 (Figs. 4.11(a) à 4.11(e), respectivamente), todos com 10% de probabilidade de mutação. Este padrão se repete em todas as outras figuras desta escolha, ou seja, até a 4.15. Para as próximas figuras, os valores de probabilidade de mutação são alterados, tendo a Figura 4.12 as otimizações com 20% de probabilidade de mutação, a Figura 4.13, 30%, a Figura 4.14, 40% e a Figura 4.15, 50%. Os valores de probabilidade de mutação estão relativamente altos devido à rotina de mutação no código de otimização apresentar uma mutação leve, com alterações dos valores não maiores que 50%.

Já na Figura 4.11 é notável que o aumento da homogeneidade da distribuição das soluções é favorecido pelo aumento do número de indivíduos no elitismo, o que também é fácil de se notar até a Figura 4.13, mas se torna mais difícil de perceber nas duas últimas. De fato, é possível notar que enquanto o aumento de indivíduos no elitismo melhora a homogeneidade, ele prejudica a fronteira por diminuir sua extensão. Por outro lado, a probabilidade de mutação, parece piorar a homogeneidade da distribuição, mas ao mesmo tempo melhora a extensão da fronteira, o que se verifica da Figura 4.11 para a 4.12. A partir da Figura 4.13, porém, a qualidade das fronteiras começa a se deteriorar quanto à homogeneidade e à sua posição (voltando para o centro ao invés de se direcionar para o canto inferior direito), embora suas extensões sejam aumentadas em alguns casos, mas as soluções que formam essas fronteiras são dominadas por aquelas vistas em alguns dos casos anteriores (Figs. 4.11 e 4.12). Por estas razões, as três últimas figuras (Figs. 4.13, 4.14 e 4.15) já permitem descartar as probabilidades de mutação que apresentaram (30%, 40% e 50%).

Ao se observar os casos das Figuras 4.11 e 4.12, dois em particular se destacam pela boa distribuição, pela extensão, bem como pelos valores de soluções encontrados, que são o da Figura 4.11(a) e o da Figura 4.12(b). Ambos encontraram diversas soluções com massa abaixo de 87 *kg*, o que não ocorre na maioria dos outros casos, sendo que na

primeira são apresentadas as menores massas encontradas em todos os casos e na segunda, as soluções com as menores massas para velocidade próxima à limite de 85 m/s . Assim, estes dois conjuntos de parâmetros serão submetidos a outros testes, juntamente com um caso intermediário, com 20% de probabilidade de mutação e 15 indivíduos no elitismo, para então definir os parâmetros a serem utilizados nos estudos de caso.

Para se determinar o número de gerações necessários para que a otimização seja robusta, tendendo sempre a conduzir para ótimos globais, propõe-se averiguar 10 rodadas de otimização com os conjuntos de parâmetros escolhidos, partindo de populações iniciais diferentes. Busca-se saber se as fronteiras finais encontradas estão próximas, ou se distam muito entre si, o que possivelmente caracterizaria ótimos locais. Estes testes são inicialmente realizados por 500 gerações, aumentando-se este valor conforme a necessidade.

A Figura 4.16 ilustra os 10 casos para 10% de probabilidade e 10 indivíduos no elitismo, por 500 gerações. Como visto, os parâmetros não são suficientes para garantir robustez à otimização, o que é sugerido pelas várias soluções distantes umas das outras. Em outras palavras, os parâmetros não garantem a convergência à fronteira de Pareto. Para 20% e elitismo de 15 indivíduos por 500 gerações (Fig. 4.17), pode-se dizer o mesmo, porém nota-se um comportamento bem melhor do que o apresentado pelo caso anterior. Isto se repete com 20% e elitismo de 20 indivíduos por 500 gerações, visto na Figura 4.18. Deste modo, mais uma sequência de testes será realizada, somente com os dois últimos casos (20% de probabilidade de mutação, 15 ou 20 indivíduos no elitismo). Ainda sobre estes três estudos de 10 casos, ressalta-se que a maioria das curvas está reunindo soluções com massa bem abaixo de 87 kg , o que mostra a superioridade dos conjuntos de parâmetros escolhidos com relação aos outros testados.

Realizou-se então nova rodada de testes, com 1.500 gerações, como mostram as Figuras 4.19 e 4.20, com 20% de mutação, elitismo de 15 e 20, respectivamente. Este número de gerações ainda não foi suficiente, conforme demonstrado nas figuras, porém pode-se observar boa melhora nas soluções, quando se comparam as Figuras 4.19 e 4.17, como

4.11(a)

4.11(b)

4.11(c)

4.11(d)

4.11(e)

Figura 4.11: Fronteiras com 10% de probabilidade de mutação, 10 à 50 indivíduos no elitismo - de (a) à (e), respectivamente.

4.12(a)

4.12(b)

4.12(c)

4.12(d)

4.12(e)

Figura 4.12: Fronteiras com 20% de probabilidade de mutação, 10 à 50 indivíduos no elitismo - de (a) à (e), respectivamente.

4.13(a)

4.13(b)

4.13(c)

4.13(d)

4.13(e)

Figura 4.13: Fronteiras com 30% de probabilidade de mutação, 10 à 50 indivíduos no elitismo - de (a) à (e), respectivamente.

4.14(a)

4.14(b)

4.14(c)

4.14(d)

4.14(e)

Figura 4.14: Fronteiras com 40% de probabilidade de mutação, 10 à 50 indivíduos no elitismo - de (a) à (e), respectivamente.

4.15(a)

4.15(b)

4.15(c)

4.15(d)

4.15(e)

Figura 4.15: Fronteiras com 50% de probabilidade de mutação, 10 à 50 indivíduos no elitismo - de (a) à (e), respectivamente.

Figura 4.16: Fronteiras de 10 casos com populações iniciais diferentes, com 10% de probabilidade e elitismo de 10, por 500 gerações.

Figura 4.17: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 15, por 500 gerações.

também as Figuras 4.20 e 4.18. Em termos didáticos, várias das curvas desceram (massas menores) e acentuaram o canto direito da curva (soluções com velocidade maior e massa menor). Contudo, destes testes ainda não se pode concluir qual conjunto de parâmetros é mais adequado, devendo-se seguir com outros, usando mais gerações.

Figura 4.18: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 20, por 500 gerações.

Figura 4.19: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 15, por 1.500 gerações.

Mais uma rodada de testes foi conduzida, desta vez por 2.000 gerações (Fig. 4.21 e Fig. 4.22). E novamente se observa melhoras nas curvas, mas os testes com este número de gerações ainda não permitem maiores conclusões.

Finalmente, testou-se os dois conjuntos de parâmetros por 3.000 gerações, conforme

Figura 4.20: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 20, por 1.500 gerações.

Figura 4.21: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 15, por 2.000 gerações.

ilustrado nas Figuras 4.23 e 4.24, de onde se pode concluir que os parâmetros mais apropriados para os estudos de caso são: 20% de probabilidade de mutação, 15 indivíduos no elitismo e 3.000 gerações de evolução. Vale ressaltar que este último pode ainda ser aumentado para garantir convergência, quando se julgar necessário.

Figura 4.22: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 20, por 2.000 gerações.

Figura 4.23: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 15, por 3.000 gerações.

Em termos de custo computacional, uma análise comparativa coerente que pode ser feita entre a otimização com modelos ou metamodelos, é com relação ao número de chamadas à função de avaliação dos indivíduos, neste caso, todos os modelos para previsão de *flutter*. Considera-se que o código de otimização utilizado seria o mesmo em ambos os

Figura 4.24: Fronteiras de 10 casos com populações iniciais diferentes, com 20% de probabilidade e elitismo de 20, por 3.000 gerações.

casos, de modo que para otimização por 3.000 gerações, com 50 indivíduos na população, o número de chamadas à função de avaliação seria igual a 150.000 ($50 \cdot 3.000$) com o uso dos modelos e nenhuma chamada durante a otimização para o caso que utiliza metamodelos. Este último utiliza (no estudo em questão) 1.000 chamadas à função de avaliação apenas na criação do banco de dados para a preparação dos metamodelos. Há que se considerar também o tempo de preparação dos metamodelos, no caso da RN, o tempo de treinamento, por volta de 10 minutos, acrescido do tempo de avaliação do banco, aproximadamente 6,7 minutos para os 1.000 indivíduos, além do tempo de otimização em si, em torno de 4,25 minutos. A Tabela 4.4 sintetiza as comparações em termos de chamadas à função, bem como em termos de tempos totais, para análises feitas em um computador pessoal (PC com processador INTEL® PENTIUM® Dual Core, 3.2 GHz e 2 Gb de memória RAM). As otimizações feitas com os modelos foram realizadas em trabalhos anteriores (CAIXETA JR., 2006; CAIXETA JR.; MARQUES, 2009b), de onde são tiradas informações dos tempos de execução, porém tais tempos foram reavaliados, dadas as mudanças efetuadas no código de otimização, tratando-se portanto de estimativas. Esta comparação evidencia os benefícios de se usar o metamodelo para a otimização proposta.

Tabela 4.4: Comparações de custo computacional.

Otimização	Chamadas à função de avaliação	Tempo total de execução [min]
Modelo	150.000	995
Metamodelo RN	1.000	20,95

4.4 Estudos de Caso

O esquema de MDO foi avaliado para duas configurações estruturais de asa. O primeiro caso a ser estudado, o qual denomina-se a partir deste momento CS1, é baseado em uma asa de grande alongamento, ilustrada na Fig. 4.25. Esta asa tem massas concentradas para representar materiais não estruturais e corpos externos. Todas as massas concentradas são de 5 kg e têm momento de inércia de $4,5\text{ kgm}^2$, exceto a massa central (que representa uma fuselagem), que é de 140 kg e tem momento de inércia de 100 kgm^2 . Este primeiro caso segue exatamente os padrões utilizados para a escolha de parâmetros (as mesmas massas concentradas).

Figura 4.25: Modelagens das asas para o primeiro estudo de caso – CS1.

Conforme definido na seção anterior, a otimização foi realizada por 3.000 gerações. A evolução da otimização para o primeiro caso é apresentada na Fig. 4.26, onde a aptidão (*fitness*), a velocidade de *flutter* e a massa estrutural da média dos indivíduos são ilustradas. Pode-se ver uma melhora razoável na aptidão, deixando um valor de menos de 2, subindo para valores em torno de 6, embora este valor, como descrito anteriormente, não seja função apenas de V_{crit} e M , mas também da fronteira em que a solução se encontra, bem como da proximidade entre as soluções. Isto explica a oscilação vista na curva de evolução da aptidão. Esta variação é também um bom indício de que o domínio de soluções está sendo amplamente explorado, um sinal de robustez. Este comportamento se deve aos operadores cruzamento e mutação, que efetuam alterações significativas durante a otimização. A evolução da média de velocidade também demonstra melhora, partindo

de menos de 60 m/s para um valor em torno de 73 m/s , enquanto a da massa parte de mais de 93 kg para aproximadamente 86 kg . Ambas reafirmam a eficácia da otimização em evoluir o conjunto de soluções, com aumento de aproximadamente $21,5\%$ da velocidade de *flutter* e diminuição de massa de $7,5\%$.

Figura 4.26: Evoluções de aptidão, V_{crit} e M para CS1.

A evolução das fronteiras de soluções não dominadas ao longo das gerações é ilustrada pela Figura 4.27, com uma vista aproximada da mesma na Figura 4.28. Nestas figuras foram apresentadas algumas fronteiras de gerações iniciais, para então mostrar a final, devido à dificuldade de se mostrar fronteiras intermediárias, visto que isto causaria grande poluição visual nos gráficos. Mas o que ocorre na evolução é um reposicionamento da fronteira, se movendo para uma posição próxima da final logo nas primeiras gerações, para então trabalhar na quantidade de soluções e em sua distribuição na fronteira nas gerações que se seguem até o fim. Isto esclarece o motivo de as curvas de evolução (Fig. 4.26), após uma evidente melhora, se manterem no mesmo patamar por várias gerações, pois nas etapas posteriores (a partir da centésima geração, aproximadamente) de uma geração para outra são acrescentadas soluções em toda a extensão da fronteira, o que não causa uma grande variação na média.

Figura 4.27: Evolução da fronteira de soluções não dominadas para CS1.

Figura 4.28: Vista aproximada da evolução da fronteira para CS1.

A Figura 4.29 apresenta a última fronteira de soluções não dominadas encontrada após 3.000 gerações. Embora não se possa afirmar que esta seja a fronteira de Pareto, ela será assim chamada por representar o melhor conjunto de soluções encontrado. Nesta figura ela está representada na mesma escala dos casos de seleção de parâmetros, para facilitar a comparação, de onde se nota que está entre os melhores casos, como vistos

na Figura 4.23. Para ver mais detalhes da fronteira, a Figura 4.30 apresenta uma vista aproximada, onde se pode observar a existência de inclinação na curva, com o aumento da velocidade crítica atrelado ao aumento da massa estrutural. Na região de 85 m/s nota-se um aumento abrupto da massa, mas essa característica certamente advém da imposição de um limite de velocidade, sendo provável que não se apresentaria caso não houvesse tal limite. Percorrendo a extensão da fronteira, para se aumentar em 19 m/s a velocidade de *flutter*, aumenta-se $0,45 \text{ kg}$ a massa estrutural. Se considerarmos uma espécie de coeficiente de inclinação geral, considerando os valores extremos da fronteira, teremos um valor de $0,024$ para tal coeficiente.

Figura 4.29: Fronteira de Pareto para CS1.

Alguns indivíduos da fronteira de Pareto foram selecionados para ilustrar os resultados encontrados, conforme apresentado nas indicações da Figura 4.31. O primeiro deles, indivíduo A (Fig. 4.32), é o mais leve de todos, ao mesmo tempo que tem a menor velocidade de *flutter*. Ele possui envergadura de $20,046 \text{ m}$, área de $21,898 \text{ m}^2$, ângulo de enflechamento do bordo de ataque (nas figuras, é o bordo superior da vista em planta, com o bordo de fuga posicionado em 0, na seção da raiz da asa) quase nulo ($\Lambda = 0,070^\circ$) e afilamento que é o menor dos quatro casos, $\lambda = 0,831$. Suas distribuições de rigidez

Figura 4.30: Vista detalhada da fronteira de Pareto para CS1.

são bastante semelhantes e partem de um valor próximo ao mínimo para a região da raiz, 90.000 Nm^2 , para então ter um decaimento grande no início (até 2 m) e suave posteriormente (a partir da posição citada). Vale lembrar que as distribuições de rigidez, embora apresentadas como curvas contínuas, são valores discretos definidos em 8 seções, sendo que o primeiro valor é definido próximo à raiz, não exatamente na raiz, mas em uma posição um pouco deslocada à direita, a $b/32$ a partir de zero. As curvas contínuas são uma interpolação para exemplificar o que seriam as características da estrutura real.

O indivíduo B, visto na Figura 4.33, tem a mesma envergadura de A ($b = 20,046 \text{ m}$) e área também muito próxima, mas levemente maior ($S = 21,902 \text{ m}^2$). Já o enflechamento é de $2,103^\circ$, bem maior, como visto na figura, enquanto o afilamento é menor $0,760$. As distribuições de rigidez não só são semelhantes entre si, mas também se aproximam daquelas do indivíduo A, bem como das que descrevem o indivíduo C (Fig. 4.34). Curiosamente, as envergaduras encontradas para todos os 4 indivíduos são exatamente iguais. Assim, o que diferencia os indivíduos de A a C, são principalmente o ângulo de enflechamento e a razão de afilamento, tendo a área em planta uma leve diferença de um caso para outro. Por fim, o indivíduo de maiores velocidade e massa, caso D, é apresentado na Figura 4.35,

Figura 4.31: Indicação dos indivíduos avaliados na fronteira de Pareto de CS1.

Figura 4.32: Indivíduo A da fronteira de Pareto de CS1.

onde se nota agora uma nova diferença com relação aos outros três, nas distribuições de rigidez. A distribuição de rigidez à torção (GJ) continua muito semelhante às outras, mas a de rigidez à flexão teve um pequeno aumento na primeira seção (seção esta que

não se encontra em $b = 0$, como dito) e um aumento considerável na segunda seção, que resultam no aumento de velocidade e massa. Seu afilamento é semelhante ao do indivíduo C, mas seu ângulo de enflechamento é mais próximo do indivíduo B, assim como sua área. A Tabela 4.5 sintetiza os valores das variáveis geométricas obtidas para os 4 indivíduos averiguados, A, B, C e D.

Figura 4.33: Indivíduo B da fronteira de Pareto de CS1.

Tabela 4.5: Variáveis geométricas dos indivíduos avaliados em CS1.

Indivíduo	b [m]	S [m ²]	Λ [graus]	λ [°]
A	20,046	21,898	0,070	0,831
B	20,046	21,902	2,103	0,760
C	20,046	21,912	2,566	0,711
D	20,046	21,905	1,926	0,714

Pela observação dos quatro indivíduos, nota-se que para CS1 o que mais diferencia as soluções dentro da fronteira são o ângulo de enflechamento e o afilamento. A envergadura tendeu para o valor mínimo e a área em planta para um valor bem próximo ao máximo, obtendo-se as outras soluções da fronteira pela variação de Λ e λ . Embora exista uma inclinação na curva da fronteira, acredita-se que se não houvesse a imposição do limite de velocidade em 85 m/s ela não só seria expandida para velocidades maiores, como

Figura 4.34: Indivíduo C da fronteira de Pareto de CS1.

Figura 4.35: Indivíduo D da fronteira de Pareto de CS1.

estas soluções teriam massas maiores e possivelmente a curva teria inclinação maior. Contudo, não é possível considerar soluções com V_{crit} maiores sem ampliar os estudos sobre a capacidade de extrapolação da RN, de modo que aquela imposição, embora seja

uma solução conservadora, parece bastante coerente dados os estudos efetuados.

O segundo caso, denominado como CS2, tem basicamente as mesmas características da asa anterior, mas com duas grandes massas concentradas nas pontas, representando tanques de ponta de asa, conforme mostra a Fig. 4.36. Assim, as massas concentradas nas asas são de 5 kg e têm momento de inércia de $4,5 \text{ kgm}^2$, a massa central, é de 140 kg e 100 kgm^2 de momento de inércia, enquanto as massas nas pontas das asas são de 30 kg e têm momento de inércia de $5,5 \text{ kgm}^2$. Esta configuração de asa tem um comportamento dinâmico bastante distinto do primeiro, embora aerodinamicamente apresente as mesmas características, o que traz diversas novas informações e por esta razão foi proposto este segundo estudo. Para este caso, uma nova rede neural teve que ser treinada, a partir de um novo banco de dados, criado com a utilização da distribuição de massas apresentada e seguindo exatamente os mesmos critérios utilizados anteriormente, inclusive a mesma arquitetura de rede.

Figura 4.36: Modelagens das asas para o segundo estudo de caso – CS2.

As curvas de evolução deste caso estão representadas na Figura 4.37, onde novamente são delineadas as curvas de evolução da aptidão, V_{crit} e M para a média da população. Como em CS1, houve um aumento na aptidão, com um valor inicial inferior a 2 sendo elevado a 3. Para a velocidade, uma média menor que 60 m/s foi elevada a aproximadamente 65 m/s enquanto para a massa estrutural, diminuiu de quase 93 kg para valores próximos a 86 kg . Para este caso, houve o aperfeiçoamento na população permitiu um aumento de $8,3\%$ em V_{crit} e diminuição de $7,5\%$ da massa estrutural. Comparado a CS1, a otimização deste caso teve a mesma eficácia sobre a massa, aliada a menor eficácia sobre a velocidade (em CS1 a velocidade média aumentou $21,5\%$), que nem se aproximou do valor limite, sendo de maneira geral mais atuante sobre a massa.

O gráfico de evolução das fronteiras (Fig. 4.38) também mostra que o percurso até

Figura 4.37: Evoluções de aptidão, V_{crit} e M para CS2.

a última geração foi menor que aquele apresentado em CS1, mas o processo evolutivo é semelhante, com um deslocamento inicial seguido de um preenchimento da fronteira, nos estágios finais. A forma das fronteiras é bastante diferente, apresentando uma inclinação média consideravelmente maior que em CS1. Retomando o coeficiente de inclinação geral, considerado inicialmente em CS1, teremos para CS2 um valor de 0,45 para o coeficiente. Isto é bastante evidente na Figura 4.39, que ilustra a fronteira de Pareto para CS2.

Figura 4.38: Evolução da fronteira de soluções não dominadas para CS2.

Na fronteira da Figura 4.39 não aparece nenhum aumento abrupto de massa, como aquele de CS1 próximo a 85 m/s . Por outro lado, as maiores velocidades estão muito distantes do limite, o que corrobora com o argumento que aquele fenômeno é fruto do limite de velocidade imposto. Ressalta-se também que apenas pela adição de massas nas pontas da asas, as maiores velocidades críticas encontradas são comparáveis às menores do outro caso, enquanto as maiores massas de CS1 têm valores semelhantes às menores de CS2.

Figura 4.39: Fronteira de Pareto para CS2.

Os indivíduos escolhidos para exposição de variáveis estão indicados na fronteira da Figura 4.40, buscando-se novamente quatro casos espaçados para maior compreensão sobre o conjunto de soluções ótimas. O caso A, extremo esquerdo da fronteira, está ilustrado na Figura 4.41. Neste indivíduo, conforme também observado no indivíduo com menores M e V_{crit} de CS1, apresenta-se o menor ângulo de enflechamento entre as 4 soluções, $0, 239^\circ$. Pelas suas características, também era de se esperar que apresentasse os menores valores de rigidez, como de fato se observa na figura. As distribuições são inclusive similares às aquelas vistas nos 3 primeiros indivíduos de CS1. Semelhantemente ao caso 1, as envergaduras dos 4 indivíduos mostrados em CS2 têm valores muito próximos, mais uma vez tendendo

ao valor mínimo (20 m), como sintetizado na Tabela 4.6. Para a área isso não se repete, tendo o indivíduo A o valor de $S = 21,055 \text{ m}^2$, próximo ao mínimo, enquanto os outros três tem valores maiores, próximos ao máximo, como os de CS1. A razão de afilamento mais expressiva deste caso (ou seja, a menor delas) é essa do indivíduo A (0,704).

Figura 4.40: Indicação dos indivíduos avaliados na fronteira de Pareto de CS2.

O indivíduo B (Fig. 4.42), assim como o D (Fig. 4.44), praticamente não tem afilamento, com valores de 0,978 e 0,995 respectivamente, já o C (Fig. 4.43) tem o afilamento considerável de 0,790. A distribuição de rigidez à flexão do indivíduo B tem um aumento na região de $1/4 \cdot b$ com relação ao indivíduo anterior, a do C teve este mesmo aumento acentuado, somado aos aumentos na primeira e na segunda seções, próximas à raiz. Por fim, a distribuição de EI do caso D sofre mais aumentos nestas primeiras seções, além daqueles vistos até aproximadamente 7 m da envergadura. Enquanto isto ocorre nas distribuições de rigidez à flexão, as de GJ se conservam praticamente inalteradas.

A Tabela 4.6 resume as variáveis geométricas dos 4 indivíduos apresentados. Ao observá-la e compará-la à Tabela 4.5, de CS1, destacam-se algumas semelhanças: todos os casos possuem envergaduras próximas ao mínimo valor possível, os dois extremos mínimos

Figura 4.41: Indivíduo A da fronteira de Pareto de CS2.

Figura 4.42: Indivíduo B da fronteira de Pareto de CS2.

(indivíduos A) têm a menor área e o menor enflechamento em seus conjuntos, e finalmente, percorrendo de A a C, o ângulo de enflechamento aumenta proporcionalmente à velocidade e à massa. Em CS2 isso ocorre de A a D e talvez, o caso D de CS1 só fuja a esta

Figura 4.43: Indivíduo C da fronteira de Pareto de CS2.

Figura 4.44: Indivíduo D da fronteira de Pareto de CS2.

característica por ser um caso que só aparece devido à imposição do limite de velocidade. As áreas também aumentam de A a D em CS2 e somente de A a C em CS1, talvez pela mesma razão.

Tabela 4.6: Variáveis geométricas dos indivíduos avaliados em CS2.

Indivíduo	b [m]	S [m ²]	Λ [graus]	λ [°]
A	20,023	21,055	0,239	0,704
B	20,024	21,904	2,665	0,978
C	20,024	21,962	2,762	0,790
D	20,024	21,965	2,937	0,995

Estas comparações sugerem que o uso de artifícios como o limite de velocidade imposto deve ser bastante cauteloso, pois pode influenciar os resultados obtidos e conduzir a soluções que não satisfaçam os requisitos de projeto. Para o problema em estudo, seria necessário um retrabalho no banco de dados de treinamento da RN e, conseqüentemente na própria RN, para tentar aumentar a faixa de velocidades das soluções, tornando assim desnecessária a imposição de um limite. Para o caso aeroelástico, contudo, isto poderia trazer outros problemas para o treinamento de uma RN, como por exemplo ter mais de um mecanismo de *flutter* em um mesmo banco. Não se pode dizer de antemão se a capacidade de aprendizado de uma rede como a implementada neste estudo seria suficiente para lidar com este tipo de problema.

Uma outra questão que necessita de mais atenção em futuros trabalhos é a sensibilidade da rede. Nenhum estudo de análise de sensibilidade foi conduzido ainda, de forma que algumas questões ficam por enquanto sem resposta: É realmente necessário o treinamento de outra rede para o estudo de CS2? Como se comparam as respostas da RN de CS1 com a de CS2 para as mesmas entradas? A princípio isto não deve funcionar bem, uma vez que o efeito das massas concentradas de cada caso está implicitamente embutido nos pesos das RNs, mas estudos mais aprofundados devem ser feitos para que esta afirmação possa ser comprovada.

Pontuadas estas questões, admite-se que o uso de metamodelos, embora apresente ganhos computacionais incontestáveis em alguns casos, pode desencadear limitações que não estariam presentes para certas aplicações. No entanto, outros usos podem ser feitos com eles, por exemplo, para ajustar os parâmetros de um algoritmo de otimização, assim como foi feito neste trabalho, para depois substituir apenas seu bloco de avaliação pelo

própria função de avaliação originalmente usada na preparação do metamodelo. Tendo em vista o número de casos de otimização que aqui foram necessários para tal ajuste (25 rodadas com 500 gerações, mais diversos casos de 10 rodadas por números de gerações diferentes), o uso de metamodelos já se justificaria.

Os casos estudados também permitem dizer que é possível e perfeitamente viável incluir estudos de previsão de *flutter* no projeto conceitual de asas de aeronaves e, mais do que isso, no projeto conceitual de aeronaves completas. Isto, como já comentado anteriormente, traz mais conhecimento aos projetistas nesta etapa do projeto, diminuindo a probabilidade de alterações futuras em decorrência da velocidade crítica de *flutter*.

Conclusões

Este trabalho apresenta alguns aspectos da metodologia de otimização multidisciplinar em projeto, trazendo uma revisão bibliográfica de diversas aplicações já realizadas, em diferentes áreas da engenharia, com disciplinas distintas. Conceitos de metamodelagem e seu emprego crescente em sistemas de MDO são também apresentados. É pontuada a questão do momento em que a disciplina da aeroelasticidade, em especial a previsão de *flutter*, é empregada durante as etapas de projeto de uma aeronave, que em geral ocorre em estágios avançados, e como pode ser vantajoso obter seus resultados já na fase de projeto conceitual.

O desenvolvimento numérico para a previsão de *flutter* é conduzido, apresentando-se detalhes do MEF para análises de dinâmica estrutural, bem como da solução aeroelástica empregada para obtenção da velocidade crítica. Mostra-se ainda conceitos de planejamento de experimentos, ao se empregar o método de amostragem por hipercubo latino para a criação dos bancos de dados, o que pode representar uma tarefa bastante difícil, uma vez que eles devem alcançar tanto quanto possível o domínio de soluções completo ou não haverá informações suficientes para que os metamodelos se ajustem corretamente ao problema. Posteriormente a sua criação, tais bancos permitiram a preparação e a avaliação da habilidade de cada uma dos metamodelos estudados para as previsões aeroelásticas. As técnicas de metamodelagem escolhidas foram o método de interpolação por funções de base radial (RBF), o método de redes neurais artificiais (RN) e um híbrido dos anteriores,

o método de redes neurais por funções de base radial (RN RBF).

Pelos resultados para previsão de *flutter*, pode-se afirmar que o método de amostragem por hipercubo latino se mostrou bastante satisfatório para a aplicação feita aqui, com distribuições adequadas das amostras pelo domínio de soluções. Todas as técnicas de metamodelagem estudadas apresentam um bom potencial para prever a velocidade crítica, contudo, é bastante evidente a superioridade das RNs, dados os erros médios de 0,15% para esta, 1,78% para a interpolação por RBF e 1,09% para a RN RBF, com desvios padrão de 0,23%, 1,70% e 1,75% respectivamente, na análise do banco de teste. Assim justifica-se a opção feita pelo uso da RN no sistema de MDO. Ressalta-se também que todos os metamodelos apresentaram grande facilidade para integrar as disciplinas deste estudo, como demonstrado por sua capacidade para prover V_{crit} e M a partir de parâmetros estruturais e geométricos. Isso revela que as técnicas de metamodelagem são ferramentas muito úteis para projetos, para explorações de domínios de soluções, ou mesmo para fins didáticos.

O AG baseado em não-dominância apresentou-se satisfatoriamente robusto e os resultados mostraram uma tendência a encontrar um conjunto de soluções ótimas globais, a chamada fronteira de Pareto, embora os estudos realizados não permitam afirmar que as soluções encontradas ao fim de cada otimização seja de fato tal fronteira. Contudo, os resultados demonstram que o uso deste tipo de AG é bastante adequado para problemas de otimização multiobjetivo. Diversas rodadas de otimização foram realizadas para a escolha dos parâmetros do AG, que são a probabilidade de mutação, o número de indivíduos no elitismo e o número de gerações de evolução.

O esquema de MDO baseado em metamodelo proposto conduziu a soluções ótimas para ambos os estudos de caso (CS1 e CS2), obtendo parâmetros coerentes para os melhores indivíduos da população, com valores bastante distintos para todas as variáveis de projeto. Quatro indivíduos da fronteira ótima de cada caso são expostos para ilustrar a variabilidade de soluções que este tipo de otimização pode oferecer. A abordagem de MDO

com uso de metamodelos é muito mais rápida para o problema dado que a outra possível implementação, baseada no modelo numérico completo. Com tal ferramenta os projetistas de aeronaves podem ter informações adequadas sobre o comportamento aeroelástico da asa no estágio de projeto conceitual, bem como poderiam explorar e aprender mais sobre o domínio das variáveis de projeto.

Finalmente, este trabalho contribui ao expandir os conhecimentos sobre o MDO como ferramenta de projeto e ao demonstrar a possibilidade de sua aplicação no projeto conceitual. A utilização de metamodelos pode ser uma maneira de viabilizar a introdução em MDOs, ou simplesmente no projeto conceitual, de disciplinas cujos modelos numéricos sejam computacionalmente caros.

Sugestões para Trabalhos Futuros

Diversas ideias surgem ao se desenvolver um trabalho como este, onde diversas metodologias são utilizadas e escolhas de parâmetros ou de técnicas devem ser feitas, muitas vezes sem o amparo de estudos detalhados em razão dos prazos disponíveis para sua execução. Algumas delas serão apresentadas nesta seção, exemplificando tópicos que complementam os estudos apresentados, ou mesmo para expandir as aplicações dos conceitos introduzidos.

No tocante ao método dos algoritmos genéticos, diversos testes, com variações de parâmetros ou do próprio código, podem ser realizados, de forma a melhorar seu desempenho. Testes com mais de um tipo (ou intensidade) de mutação ou de cruzamento, bem como com o padrão de codificação das variáveis, podem apresentar melhoras significativas no desempenho e robustez de um AG. Inúmeras técnicas e variações de AGs estão disponíveis na literatura, que permitem diversos estudos sobre o tema.

Outras técnicas de metamodelagem para previsão de *flutter* podem ser estudadas. Dentre as diversas existentes, a metodologia de *kriging* (WANG; SHAN, 2007) é bastante utilizada em trabalhos de MDO, sendo que não foram encontrados estudos de aplicações

desta em aeroelasticidade.

Uma área que também não foi contemplada aqui e que vem recebendo atenção em estudos de MDO trata da visualização dos resultados durante o processo de otimização. A visualização é interessante principalmente para sistemas que trabalhem nas etapas de projeto preliminar e detalhado, que utilizam códigos de avaliação mais onerosos, mas também poderia ser considerada no projeto conceitual.

Por fim, mais disciplinas devem ser acrescentadas ao sistema de MDO, tornando-o uma ferramenta mais útil, capaz de lidar com projetos mais complexos, embora isto deva ser algo bastante trabalhoso e aumente o custo computacional das otimizações. Entre as disciplinas de interesse para o projeto conceitual pode-se listar: aerodinâmica, estruturas (estática), mecânica de voo (estabilidade), desempenho e custos (de fabricação e operacionais).

Referências

- ABDALLA, A. M. *OMPP para Projeto Conceitual de Aeronaves, Baseado em Heurísticas Evolucionárias e de Tomadas de Decisões*. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2009.
- ANDERSON, M. B.; GEBERT, G. A. Using pareto genetic algorithms for preliminary subsonic wing design. In: *Proceedings of the 6th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*. Bellevue, WA: [s.n.], 1996.
- ANTOINE, N.; KROO, I.; WILLCOX, K.; BARTER, G. A framework for aircraft conceptual design and environmental performance studies. In: *Proceedings of the 10th AIAA Multidisciplinary Analysis and Optimization Conference*. Albany, NY: [s.n.], 2004.
- ANTOINE, N. E.; KROO, I. M. Framework for aircraft conceptual design and environmental performance studies. *AIAA Journal*, v. 43, n. 10, p. 2100–2109, oct 2005.
- ARIZONO, H.; ISOGAI, K. Application of genetic algorithm for aeroelastic tailoring of a cranked-arrowwing. *Journal of Aircraft*, v. 42, n. 2, p. 493–499, mar-apr 2005.
- BATINA, J. T.; SEIDAL, D. A.; BLAND, S. R.; BENNETT, R. M. Unsteady transonic flow calculations for realistic aircraft configurations. In: *Proceedings of the 28th AIAA/ASME/ASCE/AHS Structures, Structural Dynamics and Materials Conference*. Monterey, CA: [s.n.], 1990. Paper No. AIAA 1987-0850.
- BHATIA, M.; AJMERA, H. C.; ABHYANKAR, S. N.; MUJUMDAR, P. M.; SUDHAKAR, K. *WingOpt - An MDO Tool for Concurrent Aerodynamic Shape and Structural Sizing Optimization of Flexible Aircraft Wings*. Bombay, India, 2003. Disponível em: <<http://www.casde.iitb.ac.in/MDO/specific-studies/WingOpt.pdf>>. Acesso em: 6 abr. 2006.
- BIGGS, M. C. *Constrained Minimization Using Recursive Quadratic Programming: Some Alternative Subproblem Formulations*. New York: North-Holland, 1975. 341-349 p.
- BISHOP, J. A.; EASTEP, F. E.; STRIZ, A. G.; VENKAYYA, V. B. Influence of model complexity and aeroelastic constraints on multidisciplinary optimization of wings. *Journal of Aircraft*, v. 35, n. 5, p. 784–790, set-out 1998.
- BISPLINGHOFF, R. L.; ASHLEY, H.; HALFMAN, R. L. *Aeroelasticity*. New York: Dover Publication, Inc., 1996. 860 p.
- BUHMANN, M. D. *Radial Basis Functions: Theory and Implementations*. [S.l.]: Cambridge University Press, 2003.

- CAIXETA JR., P. R. *Otimização Multidisciplinar em Projeto de Asas Flexíveis*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2006. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18135/tde-22122006-111540/>>.
- CAIXETA JR., P. R.; ABDALLA, A. M.; MARQUES, F. D.; CATALANO, F. M. Aero-structural MDO of a spar-tank-type wing. In: *Proceedings of the 26th Congress of International Council of the Aeronautical Sciences - ICAS 2008*. Anchorage, Alaska, USA: [s.n.], 2008.
- CAIXETA JR., P. R.; MARQUES, F. D. Aeroelastic wing MDO using metamodel based on neural networks. In: *Proceedings of the 8th World Congress on Structural and Multidisciplinary Optimization - WCSMO8*. Lisbon, Portugal: [s.n.], 2009.
- CAIXETA JR., P. R.; MARQUES, F. D. Dynamic aeroelasticity constraints in multidisciplinary design optimization of flexible wings. In: *Proceedings of the XIII International Symposium on Dynamic Problems of Mechanics - DINAME 2009*. Angra dos Reis, Brazil: [s.n.], 2009.
- CAIXETA JR., P. R.; MARQUES, F. D. Neural network metamodel-based MDO for wing design considering aeroelastic constraints. In: *Proceedings of the 6th AIAA Multidisciplinary Design Optimization Specialist Conference*. Orlando, USA: [s.n.], 2010.
- CARTY, A. An approach to multidisciplinary design, analysis & optimization for rapid conceptual design. In: *Proceedings of the 9th AIAA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*. Atlanta, Georgia: [s.n.], 2002.
- CHIROKOV, A. *Scattered Data Interpolation and Approximation using Radial Basis Functions*. October 2006. Disponível em: <<http://www.mathworks.com/matlabcentral/fileexchange/10056>>.
- CHOI, S.; ALONSO, J. J.; KROO, I. M.; WINTZER, M. Multifidelity design optimization of low-boom supersonic jets. *Journal of Aircraft*, v. 45, n. 1, p. 106–118, jan-feb 2008.
- CRAIG, R. R. *Structural Dynamics*. Estados Unidos: John Wiley & Sons, Inc., 1981. 527 p.
- DEB, K. *Multi-Objective Optimization using Evolutionary Algorithms*. Chichester: John Wiley & Sons, Ltd., 2001. 497 p.
- DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. *A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II*. Kanpur, India, 2000. Technical Report 200001.
- DE BAETS, P. W. G. *A Methodology for Aeroelastic Constraint Analysis in a Conceptual Design Environment*. Tese (Doutorado) — School of Aerospace Engineering, Georgia Institute of Technology, 2004.
- DE BAETS, P. W. G.; MAVRIS, D. N. Potential formulation for aeroelastic constraint analysis in a conceptual design environment. In: *Proceedings of the 43rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*. Denver, Colorado: AIAA, 2002. AIAA 2002-1295.

- DE JONG, K. A. *Analysis of the Behavior of a Class of Genetic Adaptive Systems*. Tese (Doutorado) — College of Literature, Science and Arts, University of Michigan, 1975.
- DE JONG, K. A. Adaptive system design: A genetic approach. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-10, n. 9, p. 566–574, 1980.
- DE MARQUI JR., C.; CAIXETA JR., P. R.; CICOGNA, T. R. Aeroelastic analysis of nonlinear airfoil. In: *Proceedings of the XII DINAME International Symposium on Dynamic Problems of Mechanics - DINAME 2007*. Ilha Bela, Brazil: [s.n.], 2007.
- EPSTEIN, B.; PEIGIN, S. Robust hybrid approach to multiobjective constrained optimization in aerodynamics. *AIAA Journal*, v. 42, n. 8, p. 1572–1581, aug 2004.
- FUSATO, D.; CELI, R. Multidisciplinary design optimization for aeromechanics and handling qualities. *Journal of Aircraft*, v. 43, n. 1, p. 241–252, jan-feb 2006.
- GALLMAN, J. W.; KAUL, R. W.; CHANDRASEKHARAN, R. M.; HINSON, M. L. Optimization of an advanced business jet. *Journal of Aircraft*, v. 34, n. 3, p. 288–295, mai-jun 1997.
- GASPARINI, J. N. *Controle de Vibrações em uma Pé Inteligente de Helicóptero*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2004.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. New York: Addison-Wesley Publishing Company, Inc., 1989. 412 p.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. *Neural Network Design*. Boston, MA, USA.: PWS Publishing Co., 1996.
- HAJELA, P. Nongradient methods in multidisciplinary design optimization – status and potential. *Journal of Aircraft*, v. 36, n. 1, p. 255–265, jan-feb 1999.
- HANSEN, E. *Global Optimization Using Interval Analysis*. New York: Marcel Dekker, 1992.
- HASSIG, H. J. An approximate true damping solution of the flutter equation by determinat iteration. *Journal of Aircraft*, v. 8, n. 11, p. 885–889, nov 1971.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Upper Saddle River, NJ: Prentice-Hall, Inc., 1999. 842 p.
- HODGES, D. H.; PIERCE, G. A. *Introduction to Structural Dynamics and Aeroelasticity*. New York: Cambridge University Press, 2002. 170 p.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: Univ. of Michigan Press, 1975.
- HOOKE, R.; JEEVES, T. A. Direct search solution of numerical and statistical problems. *Journal of the Association of Computing Machinery*, v. 8, p. 212–229, 1961.
- JANARDHAN, S.; GRANDHI, R. V. Multidisciplinary optimization of an aircraft wing/tip store configuration in the transonic regime. *Engineering Optimization*, v. 36, n. 4, p. 473–490, aug 2004.

- JUN, S.; TISCHLER, V. A.; VENKAYYA, V. B. Multidisciplinary design optimization of a built-up wing structure with tip missile. *Journal of Aircraft*, v. 40, n. 6, p. 1093–1098, nov-dec 2003.
- KAPANIA, R. K.; CHUN, S. Preliminary design of a structural wing box under a twist constraint part i. *Journal of Aircraft*, v. 41, n. 5, p. 1230–1239, sep-oct 2004.
- KEANE, A. J. Statistical improvement criteria for use in multiobjective design optimization. *AIAA Journal*, v. 44, n. 4, p. 879–891, apr 2006.
- KHATIB, W.; FLEMING, P. J. An introduction to evolutionary computing for multidisciplinary optimisation. In: *Proceedings of the Second International Conference on Genetic Algorithms in Engineering Systems: Inovations and Applications*. Glasgow, UK: [s.n.], 1997. p. 7–12.
- KIM, Y.; JEON, Y. H.; LEE, D. H. Multi-objective and multidisciplinary design optimization of supersonic fighter wing. *Journal of Aircraft*, v. 43, n. 3, p. 817–824, may-jun 2006.
- KIRKPATRICK, S.; GELLAT Jr., C. D.; VECCHI, M. P. Optimization by simulated annealing. *Science*, v. 220, n. 4598, p. 671–680, 1983.
- LIU, G. R. *Mesh Free Methods: Moving Beyond the Finite Element Method*. [S.l.]: CRC Press, 2003.
- LIU, H.; WU, Z.; RAYMER, D. P. Automated scheme adjustment for conceptual aircraft design and optimization. *Journal of Aircraft*, v. 43, n. 3, p. 825–831, may-jun 2006.
- LIU, H.; WU, Z.; WANG, G. L.; WANG, X. L. Implementation of a sketch based approach to conceptual aircraft design synthesis and modeling. *Chinese Journal of Aeronautics*, v. 20, n. 4, p. 129–136, 2004.
- LIU, J. L. Intelligent genetic algorithm and its application to aerodynamic optimization of airplanes. *AIAA Journal*, v. 43, n. 3, p. 530–538, mar 2005.
- MARLER, R. T.; ARORA, J. S. Survey of multi-objective optimization methods for engineering. *Struct. Multidisc. Optim.*, Springer-Verlag, v. 26, p. 369–395, 2004.
- MARQUES, F. D. *Controle de Vibrações em uma Pá de Helicóptero*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 1993.
- MAUTE, K.; REICH, G. W. Integrated multidisciplinary topology optimization approach to adaptive wing design. *Journal of Aircraft*, v. 43, n. 1, p. 253–263, jan-feb 2006.
- MCCONNELL, K. G. *Vibration Testing: Theory and Practice*. New York: John Wiley & Sons, Inc., 1995. 606 p.
- MCKAY, M. D.; BECKMAN, R. J.; CONOVER, W. J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, American Statistical Association and American Society for Quality, v. 21, n. 2, p. 239–245, May 1979. Disponível em: <<http://www.jstor.org/stable/1268522>>.

- MEIROVITCH, L. *Computational Methods in Structural Dynamics*. Alphen aan den Rijn, The Netherlands: Sijthoff & Noordhoff, 1980. 439 p.
- MELOSH, R. J. *Structural Engineering Analysis by Finite Elements*. Englewood Cliffs, N.J.: Prentice-Hall, Inc., 1990. 308 p.
- MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. 2. ed. New York: Springer-Verlag, 1994. 340 p.
- MULLUR, A. A.; MESSAC, A. Metamodeling using extended radial basis functions: a comparative approach. *Engineering with Computers*, Springer-Verlag London Limited, v. 21, n. 3, p. 203–217, may 2006.
- NEMEC, M.; ZINGG, D. W.; PULLIAM, T. H. Multipoint and multi-objective aerodynamic shape optimization. *AIAA Journal*, v. 42, n. 6, p. 1057–1065, jun 2004.
- NEUFELD, D.; CHUNG, J.; BEHDINAN, K. Aircraft conceptual design optimization with uncertain contributing analyses. In: *Proceedings of the AIAA Modeling and Simulation Technologies Conference*. Chicago, Illinois: [s.n.], 2009.
- NUNEZ, M.; MAGINOT, J.; PADULO, M.; GUENOV, M. Integrated exploration and visualization of optimal aircraft conceptual designs. In: *Proceedings of the 50th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*. Palm Springs, California: [s.n.], 2009.
- OSTERHELD, C. M.; HEINZE, W.; HORST, P. Influence of aeroelastic effects on preliminary aircraft design. In: *Proceedings of the ICAS 2000 Congress*. [S.l.: s.n.], 2000. p. 146.1–146.10.
- PARETO, V. *Manuale di Economica Politica*. Milan, Italia: Societa Editrice Libreria, 1906.
- PEREZ, R. E.; LIU, H. H. T.; BEHDINAN, K. Evaluation of multidisciplinary optimization approaches for aircraft conceptual design. In: *Proceedings of the 10th AIAA Multidisciplinary Analysis and Optimization Conference*. Albany, NY: [s.n.], 2004.
- PINEDA, L. E.; FREGLY, B. J.; HAFTKA, R. T.; QUEIPO, N. V. Estimating training data boundaries in surrogate-based modeling. *Structural and Multidisciplinary Optimization*, v. 42, n. 6, p. 811–821, dec 2010.
- PINTER, J. D. *Global Optimization in Action*. Dordrecht: Kluwer, 1995.
- PITT, D. M.; HAUDRICH, D. P. Artificial neural network for multiple aeroelastic analysis. In: *Proceedings of the 45th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference*. Palm Springs, California: [s.n.], 2004.
- POWELL, M. J. D. An efficient method for finding the minimum of a function of several variables without calculating derivatives. *Computer Journal*, v. 7, n. 4, p. 303–307, 1964.
- RAYMER, D. P. *Enhancing Aircraft Conceptual Design Using Multidisciplinary Optimization*. Tese (Doutorado) — Department of Aeronautics, Royal Institute of Technology, 2002.

- ROSENBROCK, H. H. An automated method for finding the greatest or least value of a function. *Computer Journal*, v. 3, n. 4, p. 175–184, 1960.
- ROTH, B. D.; CROSSLEY, W. A. Application of optimization techniques in the conceptual design of morphing aircraft. In: *Proceedings of the AIAA's 3rd Annual Aviation Technology, Integration, and Operations (ATIO) Tech.* Denver, Colorado: [s.n.], 2003.
- SILVA, R. G. A. *Análise Aeroelástica no Espaço de Estados Aplicada a Aeronaves de Asa Fixa*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 1994.
- SIMPSON, T. W.; MAUERY, T. M.; KORTE, J. J.; MISTREE, F. Comparison of response surface and kriging models for multidisciplinary design optimization. In: *Proceedings of the 47th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*. St. Louis, MO: [s.n.], 1998.
- SIMPSON, T. W.; PEPLINSKI, J.; KOCH, P. N.; ALLEN, J. K. Metamodels for computer-based engineering design: Survey and recommendations. *Engineering with Computers*, Springer-Verlag London Limited, v. 17, n. 2, p. 129–150, July 2001.
- SORIANO, H. L. *Método de Elementos Finitos em Análise de Estruturas*. São Paulo: Edusp, 2003. 580 p.
- STRIBLING, C. B. *Basic Aerodynamics*. London, UK: Butterworth-Heinemann Ltd, 1984.
- TEKINALP, O.; BINGOL, M. Simulated annealing for missile optimization: Developing method and formulation techniques. *Journal of Guidance, Control, and Dynamics*, v. 27, n. 4, p. 616–626, jul-aug 2004.
- THEODORSEN, T. General theory of aerodynamic instability and the mechanism of flutter. *NACA Report*, n. 496, p. 413–433, 1934.
- THEODORSEN, T.; GARRICK, I. E. Nonstationary flow about a wing-aileron-tab combination including aerodynamic balance. *NACA Report*, n. 736, p. 129–138, 1942.
- THOMAS, C. *NASA Dryden Flight Research Center Photo Collection*. 2005. Disponível em: <<http://www.dfrc.nasa.gov/Gallery/Photo/Altair%5FPredatorB/Medium/ED05-0234-07.jpg>>.
- TORN, A.; ZILINSKAS, A. *Global Optimization, Lecture Notes in Computer Science*. Heidelberg, Germany: Springer-Verlag, 1989.
- U.S. ARMY AVIATION AND MISSILE COMMAND. *Handling Qualities Requirements for Military Rotorcraft*. Rept. ads-33e-prf. Redstone Arsenal, AL, March 2000.
- VIANA, F. A. C. *SURROGATES Toolbox User's Guide*. Version 2.1. Gainesville, FL, USA, 2010. Disponível em: <<http://sites.google.com/site/fchegury/surrogatestoolbox>>.
- VIANA, F. A. C.; HAFTKA, R. T. Cross validation can estimate how well prediction variance correlates with error. *AIAA Journal*, v. 47, n. 9, p. 2266–2270, sep 2009.

- VIANA, F. A. C.; HAFTKA, R. T.; PICHENY, V. Using cross validation to design conservative surrogates. *AIAA Journal*, v. 48, n. 10, p. 2286–2298, oct 2010.
- VIANA, F. A. C.; HAFTKA, R. T.; STEFFEN JR, V. Multiple surrogates: How cross-validation errors can help us to obtain the best predictor. *Structural and Multidisciplinary Optimization*, v. 39, n. 4, p. 439–457, oct 2009.
- VIANA, F. A. C.; STEFFEN JR, V.; BUTKEWITSCH, S.; LEAL, M. F. Optimization of aircraft structural components by using nature-inspired algorithms and multi-fidelity approximations. *Journal of Global Optimization*, v. 45, n. 3, p. 427–449, nov 2009.
- WANG, G. G. Adaptive response surface method using inherited latin hypercube design points. *ASME Transactions, Journal of Mechanical Design*, v. 125, n. 2, p. 210–220, jun 2003.
- WANG, G. G.; SHAN, S. Review of metamodeling techniques in support of engineering design optimization. *Journal of Mechanical Design*, ASME, v. 129, n. 4, p. 370–380, 2007.
- WIDMAIER, K. *Algoritmo Genético Aplicado à Otimização de Asas de Material Compósito de Veículos Aéreos Não Tripulados*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2005.
- XIONG, Y.; MOSCINSKI, M.; FRONTERA, M.; YIN, S.; DEDE, M.; PARADIS, M. Multidisciplinary design optimization of aircraft combustor structure: An industry application. *AIAA Journal*, v. 43, n. 9, p. 2008–2014, sep 2005.
- YATES JR., E. C. Modified-strip-analysis method for predicting wing flutter at subsonic to hypersonic speeds. *Journal of Aircraft*, v. 3, n. 1, p. 25–29, jan-feb 1966.
- ZAERO Version 7.2 - Theoretical Manual. [S.l.], Dezembro 2004. Disponível em: <<http://www.zonatech.com/Documentation/theoreticalmanual72.pdf>>.
- ZAPKA, B. *Northrop Grumman Corporation Flickr Gallery*. 2010. Disponível em: <<http://www.flickr.com/photos/northropgrumman/6032711795/in/photostream/>>.