JAMIL KALIL NAUFAL JÚNIOR

MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA

Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Doutor em Engenharia

São Paulo
2005

JAMIL KALIL NAUFAL JÚNIOR

MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA

Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Doutor em Engenharia

Área de concentração:
Sistemas Digitais

Orientador:
Prof. Dr. João Batista Camargo Júnior

São Paulo
2005

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.
São Paulo,_____de_____de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catalogação-na-publicação

NAUFAL JUNIOR, JAMIL KALIL
MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA / J. K. NAUFAL JUNIOR -- versão corr. -- São Paulo, 2005.
268 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

1.ALGORITMOS GENETICOS 2.INFRA-ESTRUTURA 3.AERONAUTICA 4.MODELAGEM COMPUTACIONAL 5.COMPUTAÇÂO EVOLUTIVA I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Computação e Sistemas Digitais II.t.

Dedico este trabalho a minha filha, minha esposa, meus pais e futuros netos, por todos estes anos de convívio, apoio e incentivo.

AGRADECIMENTOS

Gostaria de manifestar meus agradecimentos a todos aqueles que contribuíram de forma direta ou indireta para a realização deste trabalho.

- Ao Professor João Batista Camargo Júnior por ter me orientado ao longo de todos estes anos, desde a graduação, no mestrado e doutorado, sempre otimista, incentivando-me e acreditando em meu potencial.
- Ao Professor Edson Fregni que nos ajudou quanto a sugestões e esclarecimentos em algoritmos genéticos.
- À Professora Liria Matsumoto Sato pelos esclarecimentos de dúvidas, e ao laboratório LASB (Laboratório de Software Básico) que nos auxiliou quanto ao ambiente ONIX, de grande valia para a realização das simulações iniciais.
- Ao Allan e o Francisco do LCCA (Laboratório de Computação Científica Avançada) da USP que também nos auxiliaram quanto aos ambientes CRAY-SV1 e Cluster Alcatéia, de grande valia para a realização das simulações.
- Ao ICEA (Instituto de Controle do Espaço Aéreo), pelos contatos iniciais com a área da aviação, sempre nos auxiliando de forma cordial nos aspectos relativos à aviação, bem como nos incentivando quanto à pesquisa. O ICEA, durante mais de 1 ano, nos ajudou a selecionar entre diversas propostas de pesquisa, aquelas que poderiam ser de grande interesse e valia para a aviação, em especial para a aviação brasileira. O tema abordado neste trabalho de pesquisa foi um dos temas selecionados.
- Ao CGNA (Centro de Gerenciamento da Navegação Aérea), que nos ajudou nas especificações iniciais do problema de desbalanceamento em Infra-Estrutura Aeronáutica, bem como nos forneceu todos os dados reais necessários, para especificação, modelagem e simulação do problema.
- Ao estagiário André Koeppl, pela grandiosa ajuda nas idéias, implementações e simulações em relação ao algoritmo genético evolução por abelha rainha e os algoritmos genéticos paralelos.
- Ao estagiário Daniel Scalli Fonseca, pelo auxílio nas alterações de implementação e

simulações em relação aos algoritmos genéticos paralelos.

- Ao estagiário Diogo Ito, pela grandiosa ajuda nas idéias, implementações e simulações desde seu início, através dos algoritmos genéticos métodos de seleção por roleta e torneio.
- Ao amigo Eno Siewerdt que nos enriqueceu com seus valiosos conhecimentos em aviação, sendo de grande valia na pesquisa.
- Ao mestrando Gilberto Menezes, que me ajudou na especificação do modelo da infra-estrutura aeronáutica junto ao CGNA, bem como nas simulações e levantamentos dos gráficos de demanda de todos os setores da infra-estrutura aeronáutica e nas diversas simulações.

RESUMO

Existe atualmente na sociedade um grande número de sistemas reais de alta complexidade. Esta complexidade pode ser definida tanto do ponto de vista da dificuldade em identificar todas as partes que compõem estes sistemas, como também, pela compreensão e definição real da relação entre estas partes, permitindo, desta forma uma representação adequada do comportamento global do sistema. O comportamento global destes sistemas não se caracteriza pela soma do comportamento de suas partes componentes. Normalmente, a modelagem destes sistemas não reflete, de forma realística, o seu comportamento, devido ao excesso de simplificações realizadas. Por outro lado, alguns modelos são impraticáveis de serem aplicados, devido ao excessivo esforço computacional e a restrições de tempo.

O presente trabalho de pesquisa apresenta uma proposta de um modelo de otimização para um problema real de alta complexidade e com fortes requisitos de segurança (*safety*) encontrado na Infra-estrutura Aeronáutica Brasileira e Mundial. Este problema está relacionado ao desbalanceamento entre a capacidade e demanda em infra-estrutura aeronáutica em sistemas de transporte aéreo. Para tanto, o trabalho propõe um Modelo de Otimização de Demanda (MOD) em infra-estrutura aeronáutica, através da técnica de Inteligência Artificial denominada de Algoritmos Genéticos.

A pesquisa analisa a eficiência do modelo proposto em termos da resolução do problema, bem como quanto à qualidade das respostas apresentadas. De forma complementar é avaliada a importância de cada um dos parâmetros do modelo de otimização através da sua flexibilização.

ABSTRACT

Nowadays, in the society, there are a great number of real systems with high complexity. This complexity can be justified in function of the difficulty in identifying all parts that compose these systems, but also the complex relationship between them. The global behavior of these systems is not characterized for the addition of the behavior of its contracting parties. Normally, the modeling of these systems does not reflect its realistic behavior, due the excess of simplifications carried out. On the other hand, some models are impracticable to be solved, because the extreme computational effort necessary.

The present research develops a proposal of an optimization model for a real problem of high complexity and with hard safety requirements found in the Brazilian and world-wide aeronautical infrastructure. This problem deals with the unbalancing between the capacity and demand in infrastructure aeronautics in air transportation systems. The work considers a Demand Optimization Model (DOM) for aeronautical infrastructure through the technique of artificial intelligence denominated Genetic Algorithms.

The research analyzes the efficiency of the considered model in terms of problem resolution, as well as, the quality of the presented answers. Of complementary form, some parameters of the model were adjusted and their importance were avaluated.

SUMÁRIO

Lista de figuras

Lista de tabelas

Lista de abreviaturas

Lista de símbolos

1 INTRODUÇÃO 21
1.1 Objetivo 21
1.2 Motivação 22
1.3 Estrutura da Tese 24

2 CONTEXTUALIZAÇÃO AERONÁUTICA 28
2.1 Gerenciamento de Tráfego Aéreo 29
2.2 Fases na Execução de um Vôo 30
2.3 Divisão do Espaço Aéreo 32
2.4 Fases de Planejamento do Controle de Tráfego Aéreo 36
2.5 Crescimento do Tráfego Aéreo 36
2.6 Carga de Trabalho de Gerenciamento dos Controladores de Tráfego Aéreo 39
2.7 Posicionamento da Pesquisa 41

3 SISTEMAS COMPLEXOS 43
3.1 Conceitos Básicos 45
3.2 Problemas, Modelos e Simulações Computacionais 48
3.3 Sistemas Complexos e a Biologia 50

4 COMPUTAÇÃO EVOLUTIVA E ALGORITMOS GENÉTICOS 62
4.1 Taxonomia de Representação da Inteligência Humana 63
4.2 Algoritmos Genéticos (*Genetic Algorithms*) 66
4.3 Problemas de Otimização com Restrições 75
4.4 Diversidade Genética 78
4.5 Pressão Seletiva 79
4.6 Funções Multimodais 80

5 PROPOSTA DE UM MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA 84
5.1 Modelo de Otimização Genérico 89
5.2 Caracterização do Modelo de Otimização 104
5.3 Modelos de Algoritmos Genéticos Adotados 121

6 MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA APLICADO AO CONTEXTO BRASILEIRO 140
6.1 Infra-estrutura Aérea Simulada 140
6.2 Parâmetros Externos ao Modelo 142
6.3 Parâmetros Internos ao Modelo 144
6.4 Ambientes Computacionais de Simulação 146
6.5 Estratégia de Calibração 148
6.6 Algoritmos Genéticos Seqüenciais 152
6.7 Algoritmos Genéticos Paralelos 158
6.8 Resultados do Processo de Calibração dos Algoritmos Genéticos Seqüenciais ... 160
6.9 Resultados da Calibração dos Algoritmos Genéticos Paralelos 209

7 COMPILAÇÃO DOS RESULTADOS 224
7.1 Conclusões e Comentários Gerais da Pesquisa 224
7.2 Contribuições 232
7.3 Dificuldades Encontradas 234
7.4 Sugestões de Linhas de Pesquisa 234

8 CONCLUSÕES E CONTRIBUIÇÕES 248
8.1. Conclusões e Contribuições 248
8.2. Sugestões de Linhas de Pesquisa 250

REFERÊNCIAS 255

APÊNDICES (Em CD-Rom)

A - Dicionário de Termos Aeronáuticos

B - Curvas de Carga de Trabalho de Gerenciamento

C - Conceitos em Estatística

D – Resultados dos Algoritmos Genéticos Seqüenciais

E – Resultados de Simulação dos Algoritmos Genéticos Paralelos

F - Testes de Hipótese dos Algoritmos Genéticos Seqüenciais

G - Testes de Hipótese dos Algoritmos Genéticos Paralelos

H - Melhores Resultados Encontrados para a Otimização

LISTA DE FIGURAS

Figura 2.1 - Fases na execução de um vôo

Figura 2.2 - Visão de um trecho do espaço aéreo brasileiro

Figura 2.3 - Taxa de crescimento de demanda Mundial

Figura 2.4 - Crescimentos de atrasos devido ao crescimento de demanda

Figura 3.1 - Relacionamento entre problema, modelo e sistema

Figura 3.2 - Sistema complexo do ponto de vista computacional

Figura 3.3 - Visão geral do neodarwinismo

Figura 3.4 - Modo de ocorrência da permutação

Figura 3.5 - Modo de ocorrência da mutação

Figura 3.6 - Equilíbrio em uma população

Figura 3.7 - Dinâmica do processo de evolução

Figura 4.1 - Taxonomia da representação da inteligência humana

Figura 4.2 - Mecanismo de comunicação em algoritmos genéticos mestre-escravo

Figura 4.3 - Mecanismo de comunicação em algoritmos genéticos de pequena granularidade

Figura 4.4 - Mecanismo de comunicação em algoritmos genéticos de grande granularidade

Figura 4.5 - Mecanismo de comunicação em algoritmos genéticos paralelos em ponte

Figura 4.6 - Algoritmos genéticos paralelos hierárquicos de pequena e grande granularidade

Figura 4.7 - Algoritmos genéticos paralelos hierárquicos de grande granularidade e mestre-escravo

Figura 4.8 - Algoritmos genéticos paralelos hierárquicos de grande granularidade em ambos os níveis da hierarquia

Figura 4.9 - Espaço de solução: áreas de soluções viáveis e enviáveis

Figura 4.10 - Exemplo de função multimodal

Figura 5.1 - Diagrama de análise de situação em uma área de controle terminal de

São Paulo
Figura 5.2 - Infra-estrutura aérea hipotética
Figura 5.3 - Ocupação dos setores e aeroportos Aa, S6, S9 e Ac
Figura 5.4 - Diagrama de ocupação para o Aeroporto Aa
Figura 5.5 - Janelas de ocupação para os elementos aeronáuticos Aa, S1, S6, S9 e Ac
Figura 5.6 - Conflito de capacidade e tempo em um diagrama de ocupação
Figura 5.7 - Janela de ocupação real
Figura 5.8 - Janela de ocupação relativa
Figura 5.9 - Alteração da janela de ocupação real da aeronave AE1
Figura 5.10 - Novo diagrama de ocupação real para o aeroporto Aa
Figura 5.11 - Sobreposição de ocupação em Aa, S1, S6, S9 e Ac devido a uma nova janela de ocupação da aeronave AE1
Figura 5.12 - Novos diagramas de ocupação para os elementos aeronáuticos Aa, S1, S6, S9 e Ac
Figura 5.13 - Método de amostragem
Figura 5.14 - Determinação da carga de trabalho de gerenciamento instantânea para um setor
Figura 5.15 - Erro devido à taxa de amostragem
Figura 5.16 - Diminuição de erro com a diminuição da taxa de amostragem
Figura 5.17 - Cromossomo para o modelo de otimização de demanda
Figura 5.18 - Aplicação do operador permutação
Figura 5.19 - Aplicação do operador mutação
Figura 5.20 - Plano de vôo real de uma aeronave dentro do cenário aeronáutico
Figura 5.21 - Fluxograma do modelo de otimização de demanda
Figura 5.22 - Método da roleta
Figura 5.23 - Método de Seleção por Roleta
Figura 5.24 - Método de Seleção por Torneio
Figura 5.25 - Evolução por Abelha Rainha
Figura 5.26 - Modelo em Ponte

Figura 5.27 - Mapeamento dos campos de controle do bastão
Figura 5.28 - Mensagens trocadas entre ilhas
Figura 5.29 - Ilha escrava baseada em Evolução por Abelha Rainha
Figura 5.30 - Tratamento dos emigrantes e imigrantes no algoritmo genético paralelo em Ponte
Figura 6.1 - Infra-estrutura aérea estudada
Figura 6.2 - Topologia física do ambiente alcatéia
Figura 6.3 - Diagramas de análise de situação não e com a melhor otimização setor XP01
Figura 6.4 - Diagramas de análise de situação não e melhor otimização para o setor XP03
Figura 6.5 - Diagramas de análise de situação não e melhor otimização para o setor BS02
Figura 6.6 - Estudo efeito da amostragem sobre a demanda
Figura 7.1 - Acoplamento entre meta-algoritmo genético e algoritmo genético principal
Figura 7.2 - Modificação da pressão seletiva pela parametrização dos algoritmos genéticos
Figura 7.3 - Topologia proposta e esquema de migração dos melhores cromossomos
Figura 7.4 - Diagrama de análise de estado e definição de variáveis lingüísticas

LISTA DE TABELAS

Tabela 5.1 - Tempos de ocupação de cada setor e aeroporto

Tabela 6.1 - Setores e capacidades nominais declaradas do cenário aeronáutico estudado

Tabela 6.2 - Estimativa de esforço computacional de simulação

Tabela 6.3 - *Sets* criados para o algoritmo genético seleção por roleta e torneio

Tabela 6.4 - *Sets* criados para o algoritmo genético evolução por abelha rainha

Tabela 6.5 - Melhores *sets* para população de 250 cromossomos

Tabela 6.6 - Melhores *sets* para população de 500 cromossomos

Tabela 6.7 - Melhores *sets* para população de 1000 cromossomos

Tabela 6.8 - Parâmetros relacionados a Carga de Trabalho

Tabela 6.9 - Parâmetro relacionados a Custo

Tabela 6.10 - Parâmetros relacionados a Atrasos

Tabela 6.11 - *Sets* para análise de parâmetros

Tabela 6.12 - *Sets* com flexibilizações isoladas dos parâmetros

Tabela 6.13 - *Sets* com flexibilizações simultâneas dos parâmetros

Tabela 6.14 - Diversos casos de flexibilização analisados

LISTA DE SIGLAS E ABREVIATURAS

ACC	-	*Area Control Center*
ADN	-	Ácido Desoxirribonucléico
ANSI	-	*American National Standard Institute*
APP	-	*Approach Control*
ATC	-	*Air Traffic Control*
ATFM	-	*Air Traffic Flow Management*
ATM	-	*Air Traffic Management*
ATM-FMP	-	*Air Traffic Flow Management - Flow Management Point*
CAA	-	*Civil Aviation Authority*
CDM	-	*Colaborative Decision Making*
CGNA	-	Centro de Gerenciamento da Navegação Aérea
CFMU	-	*Central Flow Management Unit*
CNS/ATM	-	*Communications, Navigation and Surveillance Systems/Air Traffic Management*
CPU	-	*Central Process Unit*
DASA	-	*Deutsche Aerospace*
DOM	-	*Demand Optimization Model*
DORA	-	*Directorate of Operational Research and Analysis*
EUROCONTROL	-	*European Organization for the Safety of Air Navigation*
FA	-	Função de aptidão
FIFO	-	*First in, First Out*
HPC	-	*High Performance Computing*
IA	-	Inteligência artificial
IC	-	Inteligência computacional
ICEA	-	Instituto de Controle do Espaço Aéreo
IDE	-	*Intergrated Drive Electronics*
IFR	-	*Instrument Flights Rules*

KADS	-	*Knowledge Acquisition and Documentataion Structuring*
LASB	-	Laboratório de Software Básico
LCCA	-	Laboratório de Computação Científica Avançada
MBB	-	*Messerschmidt, Boelkow & Blohm*
MOD	-	Modelo de otimização de demanda
MPI	-	*Messege Passing Interface*
NP	-	*Non Polinomial*
OACI	-	*International Civil Aviation Organization*
PPSN	-	*Parallel Problem Solving from Nature*
RAM	-	*Random Access Memory*
RPL	-	*Repetitive Flight Plans*
SCSI	-	*Small Computer System Interface*
SMP	-	Multiprocessadores Simétricos com Memória Compartilhada
TMA	-	*Terminal Maneuvering Area*
TWR	-	*ToWeR control*
VOR	-	*Very High Frequency Omni directional Range*
WL	-	*Workload*

LISTA DE SÍMBOLOS

$C_{(e)}$	-	Complexidade de entrada de um Sistema
$C_{(a)}$	-	Complexidade de ações de um sistema
$C_{(f)}$	-	Complexidade de funcional de um sistema
T	-	Timina
C	-	Citosina
A	-	Adenina
G	-	Guanina
$eval_{(x)}$	-	Função de avaliação
$f_{(x)}$	-	Função a ser avaliada
$p_{(x)}$	-	Função de penalidade
DG	-	Diversidade Genética
AP	-	Quantidade de alelos existentes na população
AT	-	Quantidade de alelos teoricamente possíveis na população
I	-	Intensidade seletiva
f	-	Aptidão média da população
f*	-	Valor esperado da aptidão
σ	-	Desvio padrão
fc_i	-	Aptidão compartilhada do i-ésimo indivíduo
f_i	-	Aptidão original de um indivíduo
m_i	-	Número de indivíduos em um mesmo nicho
A_n	-	Aeroporto n
R_{xy}	-	Rota que interliga os aeroportos x e y
S_t	-	Setor t
C_i	-	Capacidade do setor ou aeroporto i
AE_n	-	Aeronave AE_n
te_i	-	Tempo de entrada de uma aeronave em um setor i
ts_i	-	Tempo de saída de uma aeronave em um setor i

tp_{min}	-	Tempo de permanência mínimo
$tp_{máx}$	-	Tempo de permanência máximo
$\Delta Real_i$	-	Tempo de permanência real
AE_n	-	Aeronave n
Δt	-	Intervalo de tempo de amostragem
t_i	-	Tempo de tomada de amostragem i
n_k	-	Número de elementos aeronáuticos (aeroportos e setores) em cada rota k
p_{jk}	-	Número de aeronaves no elemento aeronáutico EA_j da rota k
EA_j	-	Elemento aeronáutico j
Id_{ijk}	-	Intervalos de discretização de tempo utilizados para levantamento da demanda para cada aeronave AE_i, ocupando um elemento aeronáutico EA_j, da rota k
Π	-	Produtória
m	-	Número de rotas do cenário aeronáutico em análise
n,p	-	Número de elementos aeronáuticos em cada rota m indistintamente
Id	-	Intervalo de discretização independente do elemento aeronáutico
w	-	Número de bits dentro de um intervalo de discretização
δ	-	Porcentagem de tempo a menos do tempo de permanência nominal
η	-	Porcentagem de tempo a mais do tempo de permanência nominal
τ	-	Porcentagem de tempo a menos e a mais do tempo de permanência nominal
FO	-	Função Objetivo
ES_n	-	Estouro de capacidade de cada setor *n*
TDE_n	-	Tempo de duração do estouro do setor ES_n.
B_n	-	Base estimada para ES_n e TDE_n
ν e ρ	-	Penalidades
D_{tn}	-	Demanda no instante de observação *t* do setor *n*

CND_n	-	Capacidade nominal declarada do setor *n*
FO Auxiliar	-	Função Objetivo Auxiliar
AS_m	-	Atrasos em solo no aeroporto *m*
AVD_n	-	Atrasos em vôo das aeronaves dentro do setor *n*
t_{pr}	-	Tempo de permanência real dos vôos no setor *n*
T_{pn}	-	Tempo de permanência padrão dos vôos no setor *n*
AEA_p	-	Atrasos de entrada e saída das aeronaves no setor *p*
Ps_i	-	Probabilidade de seleção do cromossomo *i* associado ao setor s_i da roleta
n_i	-	Probabilidade acumulada de seleção até o cromossomo *i*
t_r	-	Taxa de reprodução
v_r	-	Variável aleatória reprodução
t_m	-	Taxa de mutação
v_m	-	Variável aleatória mutação
q	-	Número de cromossomos da população de torneio
ε	-	Taxa de mutação normal
p_{mn}	-	Probabilidade de mutação normal
p_{sm}	-	Probabilidade de supermutação
v_{mn}	-	Variável aleatória de mutação normal
α, β	-	Parâmetros calculados dinamicamente a cada geração
x_i	-	Valor médio
S	-	Desvio padrão amostral
Ic	-	Intervalo de confiança
$\bar{x}$	-	Média populacional da amostra
$z_{\alpha/2}$	-	Coeficientes de confiança a partir de uma distribuição populacional conhecida
Y	-	Valores da distribuição *t-student*
γ	-	Graus de liberdade
μ	-	Estimativa de média populacional

A introdução ao trabalho de pesquisa apresenta o objetivo, motivação, dificuldades encontradas e o estado da arte, que levaram à concepção da tese, bem como, a sua estruturação interna.

1 INTRODUÇÃO

"O desejo de conhecimento é o mais natural. Experimentamos todos os meios suscetíveis de satisfazê-lo, e quando a razão não basta apelamos para a experiência. Através de várias provas, a experiência cria a arte e o exemplo alheio mostra-nos o caminho".

Michel de Montaigne, Ensaios, livro III, cap.13,
São Paulo, Abril S.A. Cultura, 1972)

1.1 Objetivo

Este trabalho de pesquisa tem por objetivo primordial investigar a otimização do processo de busca da melhor solução em sistemas complexos, com especial atenção àqueles sistemas de aplicação crítica quanto à segurança (*safety*).

Neste sentido, este trabalho de pesquisa propõe um Modelo de Otimização de Demanda (MOD) para o problema de desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica, baseado em algoritmos genéticos, diminuindo conseqüentemente, a carga de trabalho de gerenciamento sobre os controladores de tráfego aéreo e aumentando, desta forma, os níveis de segurança.

Como estudo de caso do trabalho de pesquisa, foi selecionado um contexto aeronáutico brasileiro, compreendendo as áreas entre Belo Horizonte, Brasília, Rio de Janeiro e São Paulo. Estas são as áreas mais críticas dentro do contexto aeronáutico brasileiro[1].

Em seguida é realizada uma análise comparativa crítica de todos os resultados obtidos, visando a obtenção da melhor arquitetura e algoritmo genético, como também a melhor adequação das respostas das otimizações em relação aos requisitos do problema analisado.

[1] Centro Tecnológico da Aeronáutica, Centro de Gerenciamento e Navegação Aérea, **Reunião de estudo**, São José dos Campos, em 15 março de 2003. Comunicação Verbal através de especialistas em tráfego aéreo.

1.2 Motivação

Existe, atualmente na sociedade, um grande número de sistemas que são difíceis de serem compreendidos e analisados. Esta dificuldade pode estar relacionada, entre outros, a um ou mais dos seguintes fatores:

a) Ao grande número de variáveis que estes sistemas possuem, dificultando a sua compreensão e análise.
b) Dificuldade em identificar todas as variáveis que direta ou indiretamente interferem no comportamento do sistema, bem como, identificar o grau de interferência de cada uma destas variáveis.
c) Dificuldade em entender de forma precisa e coesa, como as diferentes variáveis do sistema se relacionam e definem o seu comportamento.
d) Dificuldade em criar um modelo computacional capaz de acompanhar a dinâmica de mudança de comportamento do sistema ao longo do tempo. Normalmente, estes sistemas apresentam uma grande interação com o meio onde estão inseridos, e alteram o seu comportamento em função de alterações neste meio.
e) Para um dado modelo computacional, a não existência de algoritmos eficientes que consigam representar a sua dinâmica, bem como fornecer resultados, mesmo que aproximados, mas de forma consistente, em um período de tempo aceitável.

Devido a estes fatores, torna-se de grande complexidade a criação de modelos computacionais, capazes de representarem fielmente o comportamento real de determinados sistemas.

Em engenharia existe uma grande variedade de problemas e sistemas reais, que podem ser modelados e analisados computacionalmente. Estes problemas e sistemas são reconhecidos de alta complexidade, tais como, Reconhecimento de Padrão, Otimização Combinatória, Controle Adaptativo, Controle de Tráfego Aéreo, Correlação de Alarmes em Redes de Comunicação (BAR, 2002) e (NAUFAL, 2000) entre outros.

Muitos sistemas complexos apresentam, em comum, o fato de apresentarem o tempo de busca para a sua solução ótima extremamente elevado. Este tempo de busca pode levar semanas, meses, anos, ou até mesmo séculos para se obter a sua solução exata.

Dependendo dos requisitos temporais (*Hard Real Time Systems*), o tempo excessivo para obter a solução, torna sua aplicação inviável e sem eficácia. Normalmente, em muitos destes sistemas uma solução aproximada já é suficiente.

Atualmente, a evolução e automação dos sistemas de controle de tráfego aéreo se faz necessária, devido ao crescente número de aeronaves em operação. A taxa de crescimento do tráfego aéreo mundial nos próximos 15 anos estará, em pelo menos entre 3% a 5% ao ano (TOMLIN; PAPPAS; SASTRY, 1996). Os sistemas de controle de tráfego aéreo atuais não estão preparados para manipular este crescente volume de tráfego, podendo destacar os seguintes fatores limitantes:

- Utilização ineficiente do espaço aéreo: atualmente o espaço aéreo é rigidamente estruturado, sendo que as aeronaves são forçadas a seguirem rotas pré-definidas ao longo de trajetórias. Estas rotas, geralmente não otimizadas, não permitem que as aeronaves sigam diretamente a seus destinos, aproveitando as vantagens de uma rota direta. Este problema é evidente em rotas transatlânticas que apresentam maior demanda (15% da demanda total ao ano) (TOMLIN; PAPPAS; SASTRY, 1996).
- Sobrecarga de trabalho de gerenciamento nos Centros de Controle: a manutenção da separação e acompanhamento das aeronaves, de forma a se evitar riscos de colisão, é uma das principais atribuições do controle de tráfego aéreo (ATC - *Air Traffic Control*). Em áreas congestionadas, tais como, regiões próximas a aeroportos urbanos, este problema torna-se ainda mais crítico.
- O desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica, provoca grandes congestionamentos, principalmente em regiões próximas a aeroportos, tornando a carga de trabalho (*Workload*) dos controladores de tráfego aéreo extremamente elevada. Este fato pode colocar a segurança (*safety*) do sistema de transporte aéreo em níveis inaceitáveis (SIEWERDT, 2002).
- Este congestionamento excessivo traz outras conseqüências, como crescentes atrasos na aterrisagem e decolagem dos vôos, o que provoca aborrecimento de passageiros e perda financeira às companhias aéreas.
- A tecnologia computacional utilizada em muitos ATCs é de aproximadamente 30 anos atrás (SIEWERDT, 2002). Este fato torna-se ainda mais grave, se for observado

que toda a comunicação entre ATCs e aeronaves é restrita à comunicação de voz. Em locais congestionados as aeronaves são obrigadas a realizarem sobre-vôos mais distantes, o que acarreta um custo adicional às companhias aéreas.

- Ausência de sistemas computacionais que auxiliem na otimização e melhoraria da eficiência da utilização das aeronaves e recursos aeronáuticos, garantindo-se níveis de segurança *(safety)* aceitáveis.

Muitas das atividades realizadas na área aeronáutica apresentam diferentes níveis de complexidade, sendo estas muitas vezes baseadas somente no julgamento humano (ITANI, 2003). Este fato torna-se ainda mais grave se levar em consideração o aumento de tráfego e a sobrecarga de trabalho humano dentro dos ATCs.

Em função dos fatores limitantes citados, a comunidade internacional responsável pelo ATM, vem pesquisando e propondo uma nova abordagem denominada CNS/ATM (*Communications, Navigation and Surveillance Systems Air Traffic Management*) que empregará tecnologias digitais, incluindo satélites e vários níveis de automação, como suporte global ao Gerenciamento de Tráfego Aéreo, permitindo assim sua total integração (CANSO, 1999).

Neste contexto, este trabalho de pesquisa propõe um Modelo de Otimização de Demanda (MOD) para o problema de desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica.

A confiança das autoridades, organismos e administradores dos sistemas de tráfego aéreo irão aumentar, na medida em que tais técnicas e tecnologias tornem-se conhecidas, amadurecidas e, principalmente, utilizadas efetivamente como ferramentas computacionais de apoio à decisão.

1.3 Estrutura da Tese

Este trabalho de pesquisa está organizado em 7 capítulos, apresentando a seguinte abordagem em cada um deles:

Capítulo 1: Introdução

Apresentação da tese através dos seus objetivos e aspectos motivacionais que levaram a sua realização, e seu posicionamento dentro do contexto científico.

Capítulo 2: Conceituação Aeronáutica

Apresenta os conceitos básicos relacionados à área de aviação, que estão diretamente relacionados ao trabalho de pesquisa. O objetivo deste capítulo é a familiarização com os jargões e conceitos relativos a área aeronáutica, de forma a permitir um melhor entendimento do trabalho realizado. Adicionalmente, é apresentado o problema de desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica, e seus reflexos na carga de trabalho de gerenciamento dos Controladores de Tráfego Aéreo, bem como, nos Níveis de Segurança (*safety*) do Sistema de Transporte Aéreo.

Capítulo 3: Sistemas Complexos

Neste capítulo são apresentados aspectos conceituais relacionados a sistemas complexos. Também são apresentados alguns conceitos de sistemas complexos relacionados à área de biologia, fundamentais para o entendimento da computação evolutiva.

Capítulo 4: Computação Evolutiva

Este capítulo apresenta as principais características da computação evolutiva, com especial atenção aos algoritmos genéticos, principal foco deste trabalho de pesquisa. A computação evolutiva é apresentada como uma alternativa na otimização de sistemas complexos.

Capítulo 5: Proposta de um Modelo de Otimização de Demanda em Infra-Estrutura Aeronáutica

Apresenta a proposta do Modelo de Otimização de Demanda (MOD) em infra-estrutura aeronáutica. Também são detalhados a sua função objetivo (aptidão) e critérios auxiliares utilizados dentro do contexto do problema analisado, bem como, sua conceituação e implementação através de algoritmos genéticos seqüenciais e paralelos.

Capítulo 6: Estudo de Caso – Aplicação do Modelo de Otimização de Demanda no Contexto Brasileiro

Apresenta o estudo de caso no qual é definido o problema de desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica dentro do contexto brasileiro, abordado através do cenário aeronáutico real que inclui as regiões de Belo Horizonte, Brasília, Rio de Janeiro e São Paulo. São apresentadas as diversas etapas e fases adotadas com seus resultados. Adicionalmente, são analisadas algumas sugestões de

alterações (flexibilizações) dos parâmetros do modelo, definidos a priori, de forma a procurar reduzir, ainda mais, a carga de trabalho de gerenciamento em cada um dos setores da infra-estrutura aeronáutica.

Capítulo 7: Compilação dos Resultados

Apresenta uma compilação dos resultados deste trabalho de pesquisa a partir do estudo de caso realizado. Também são apresentadas as futuras linhas de pesquisa que podem ser desenvolvidas.

Capítulo 8: Conclusões e Contribuições

Apresenta as principais conclusões e contribuições a partir da compilação dos resultados do capítulo anterior, bem como um resumo das futuras pesquisas que podem ser realizadas.

Referências

Apresenta as referências bibliográficas utilizadas.

Apêndices

Apresenta informações complementares tais como: conceitos, tabelas de dados experimentais e análises estatísticas utilizados ao longo do trabalho de pesquisa, que apesar de não estarem no texto principal da tese, merecem acompanhar o trabalho de pesquisa. Os mesmos se encontram em CD-Rom.

Neste capítulo são apresentados alguns conceitos e termos relacionados à área aeronáutica, com o objetivo de permitir um melhor entendimento do problema abordado neste trabalho de pesquisa.

2 CONTEXTUALIZAÇÃO AERONÁUTICA

Ainda não são passados cem anos desde que o homem alçou vôo por seus meios naquela tarde em Bagatelle, em Paris, e já presenciamos uma significativa evolução e um extraordinário desenvolvimento nesta moderna atividade de transporte: o avião.

A Gênese, Aeroespaço, Normando Araújo de Medeiros, Major Brigadeiro do AFR/R, Ano X - N° 14, Agosto de 2000

Para um melhor entendimento do problema de otimização de demanda em infra-estrutura aeronáutica, é necessário apresentar uma visão geral, bem como os conceitos básicos relacionados à área aeronáutica, mais precisamente sobre os sistemas de transporte aéreo.

Basicamente, um sistema de transporte aéreo pode ser dividido de forma estrutural em (OLIVEIRA, 2003) e (DECRETO LEI Nº 32, 1966):

- **Transportadores Aéreos**: executores do processo de transporte, as operadoras de linhas aéreas, incluindo suas aeronaves, infra-estrutura (equipamentos, oficinas, etc) e profissionais especializados.
- **Aeroportos**: são os pontos de acesso aos serviços dos transportadores aéreos, as instalações físicas e serviços de apoio às operações de embarque e desembarque das aeronaves.
- **Serviço de tráfego**: responsável por toda coordenação e utilização dos aeroportos e do espaço aéreo pelos transportadores aéreos.

Como pode ser visto, cada uma destas estruturas apresentam uma função específica e complementar ao objetivo final, que é fornecer o serviço de transporte de aéreo de forma segura e eficiente.

A seguir são apresentados alguns conceitos fundamentais na área aeronáutica com o objetivo de fornecer um melhor entendimento e posicionamento deste trabalho de pesquisa. O Apêndice[1] A - Dicionário de Termos Aeronáuticos, apresenta a definição de alguns termos específicos dentro do contexto aeronáutico.

2.1 Gerenciamento de Tráfego Aéreo

O gerenciamento de tráfego aéreo (ATM - *Air Traffic Management*) relaciona-se aos diversos elementos do sistema de controle de tráfego aéreo, apresentando um exigente requisito de gestão da informação, sem a qual os elementos não podem operar adequadamente.

O gerenciamento de tráfego aéreo consiste em processos através dos quais as opções de utilização do espaço aéreo são selecionadas de forma a atender às necessidades da comunidade e usuários dos serviços de transporte aéreo (ICAO, 1984). Existem diversas atividades que devem ser desenvolvidas e pesquisadas dentro do gerenciamento de tráfego aéreo, no contexto do sistema CNS/ATM. Algumas delas são citadas a seguir.

2.1.1 Organização e Gerenciamento do Espaço Aéreo

A organização e gerenciamento do espaço aéreo é um elemento fundamental, pois estabelece as estruturas do espaço aéreo mais adequadas para acomodar os diversos tipos de atividades aeronáuticas a serem disponibilizados, variados volumes de tráfego aéreo e diferentes níveis de serviços a serem prestados.

É um elemento essencial para melhorar as opções de utilização do espaço aéreo, permitindo a livre escolha de rotas diretas ou de maior conveniência para os diferentes operadores dos serviços de transporte aéreo.

[1] Os apêndices deste trabalho de pesquisa estão sendo apresentados em CD-Rom localizado no lado interior da contracapa do volume da tese.

2.1.2 Balanceamento de Capacidade e Demanda

O balanceamento de capacidade e demanda avaliará, de forma estratégica e no âmbito total do sistema, os fluxos de tráfego e as capacidades dos elementos da infra-estrutura aeronáutica. Desta forma, os usuários do espaço aéreo poderão determinar quando, onde e como podem operar, mitigando as demandas conflitantes e os recursos aeronáuticos disponíveis. Deverá ser um processo colaborativo que, através do amplo uso de informação antecipada sobre a carga no sistema, situação do cenário aeronáutico e recursos disponíveis, viabilizará a gestão eficiente do fluxo de tráfego aéreo.

2.1.3 Sincronização do Tráfego Aéreo

A sincronização do tráfego aéreo está relacionada ao estabelecimento tático e consistente de um fluxo de tráfego aéreo seguro, ordenado e eficiente. A sincronização do tráfego aéreo fará uso de sistemas integrados e automatizados para a gestão das operações das aeronaves no solo, partida e chegada em vôo. O objetivo será eliminar pontos críticos e finalmente obter a máxima utilização e produtividade das pistas de pouso e decolagem nos aeroportos.

2.1.4 Gerenciamento de Provisão de Serviços

O gerenciamento de provisão de serviços, também denominada por CDM (*Colaborative Decision Making*) (CORREA, 2004), assegurará as operações para todas as fases de vôo, ao longo das diversas áreas de responsabilidade de todos os provedores de serviços de transporte aéreo. Esta atividade tratará de balancear e consolidar as decisões emanadas dos diversos serviços, bem como os limites temporais e as condições determinantes para essas decisões. Trata-se de um elemento vital para obter cenários transparentes para a condução de todos os vôos.

2.2 Fases na Execução de um Vôo

A maior parte dos vôos comerciais seguem um procedimento denominado de IFR (*Instrument Flight Rules*) (IMA 100-12, 1999), baseado somente em dados fornecidos por instrumentos. Neste caso, referências visuais são apenas consideradas como apoio secundário. O procedimento de vôo IFR é composto das seguintes fases (OLIVEIRA, 2003]:

a) Plano de vôo

Fase em que é desenvolvido um planejamento do vôo a ser submetido à aprovação da autoridade pelo controle de tráfego aéreo.

b) Táxi

Inicia-se quando a aeronave solicita autorização ao controle de solo do aeroporto para iniciar o seu deslocamento em solo. Esta fase termina quando a aeronave chega à cabeceira da pista de decolagem. Nesta fase a aeronave está sob controle de solo e/ou da torre de controle (TWR - *Tower Control*), dependendo do local específico onde as aeronaves se encontrem.

c) Decolagem e subida inicial

Inicia-se quando a aeronave recebe autorização da torre de controle para decolagem, e termina quando ela cruza uma dada altitude de transição. A partir desta altitude de transição, a aeronave deixa de estar sob vigilância da torre de controle, e começa a haver uma interação com o controle de aproximação (APP - *Approach Control*).

d) Saída da área de controle terminal

Após esta subida inicial, começa um procedimento que liga o aeroporto de partida à aerovia. O perfil de vôo é ascendente e a aeronave está sob responsabilidade do controle de aproximação (APP).

e) Navegação em rota

Deixando a área de controle terminal (TMA - *Terminal Maneuvering Area*), a aeronave passa ao controle do centro de controle de área (ACC - *Area Control Center*). Nesta fase a aeronave atinge e mantém altitude e velocidade de cruzeiro, até que chegue às proximidades da área de controle terminal destino.

f) Aproximação

Execução de um procedimento que conecta a aerovia ao aeroporto destino. A aeronave passa a estar sob responsabilidade de um novo controle de aproximação. Executa-se um processo de vetoração das aeronaves, que objetiva garantir o seqüenciamento e espaçamento entre aeronaves em forma de uma fila de chegada em cada área de controle terminal.

g) Segmento de aproximação final

Inicia-se no instante em que a aeronave atinge uma distância mínima pré-estabelecida do aeroporto até que toque a superfície da pista. Nesta fase, a aeronave está sob vigilância primária da torre de controle. O procedimento de aproximação é realizado por instrumentos, durante o qual são executados o alinhamento e descida para o pouso.

h) Pouso e táxi

Consiste no pouso e no deslocamento da aeronave até o ponto de desembarque de passageiros e/ou cargas. Nesta fase a aeronave está sob controle da torre de controle (TWR).

A figura 2.1 ilustra todas as fases de execução de um vôo.

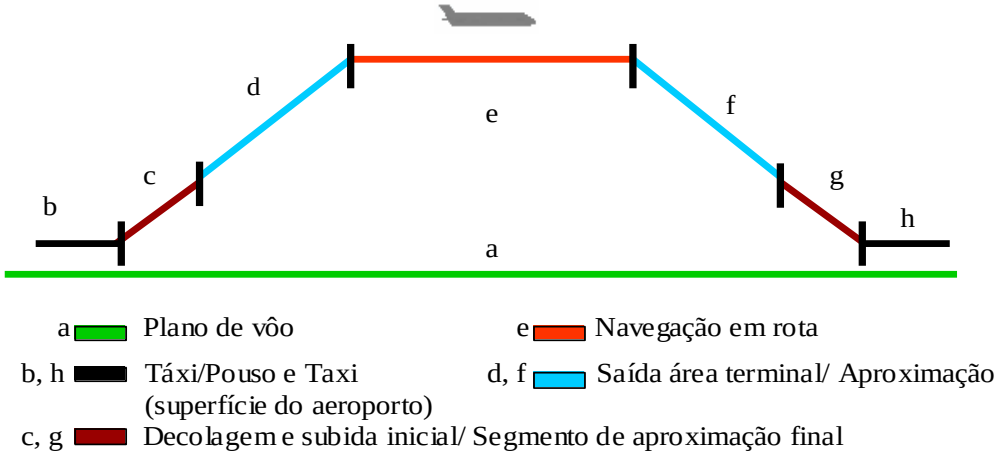

Figura 2.1: Fases na execução de um vôo

2.3 Divisão do Espaço Aéreo

Atualmente, todas as rotas e aerovias existentes em territórios nacionais e internacionais passam por caminhos pré-definidos, ou seja, caminhos fixos que facilitam a localização das aeronaves. A falta de flexibilidade nas rotas e aerovias está basicamente relacionada à falta de auxílios suficientes à navegação, de forma a permitir maior liberdade na trajetória das aeronaves (LOZITO; MCGANN; MACKIONTOSK, 1999). Uma maior flexibilização provocaria um aumento na probabilidade de conflito e de risco de acidentes, ou seja, diminuiria os níveis de segurança (*safety*) hoje praticados.

Assim, o espaço aéreo é mapeado através de planos de vôo repetitivos (RPL - *Repetitive Flight Plans*) que compõem as Cartas Aeronáuticas. Quando há a necessidade de uma nova rota, ela deve ser submetida à aprovação da autoridade aeronáutica e passará a ter o valor de "norma", sendo inserida nas Cartas Aeronáuticas (OLIVEIRA, 2003).

O espaço aéreo é dividido em grandes áreas de controle, sendo a maioria delas coberta por radares e um sistema de processamento de dados. Esta cobertura permite o processamento dos planos de vôos das aeronaves, bem como sua identificação no espaço aéreo. Todas estas áreas também possuem redes de telecomunicações entre as aeronaves e os controles.

O espaço aéreo é cortado por diversas aerovias, que representam corredores ou rotas, pelas quais as aeronaves se deslocam de um local para outro. Adicionalmente, o espaço aéreo também é dividido em espaço aéreo superior (acima de 24.500 pés) e inferior (abaixo de 24.500 pés) (OLIVEIRA, 2003). No espaço aéreo superior encontra-se a altitude ótima de cruzeiro, na qual as aeronaves comerciais apresentam o melhor rendimento com o menor consumo de combustível.

O controle das aeronaves desde sua movimentação no solo, decolagem, evolução no espaço aéreo, até a aterrisagem em seu destino, é feito por três órgãos:

- A torre de controle (TWR): orienta a movimentação das aeronaves no solo, na decolagem e no pouso. Atua até uma distância aproximadamente de 5 milhas náuticas (9,25 Km) dos aeroportos (IMA 100-12, 1999).
- O controle de aproximação (APP): recebe as aeronaves que decolam da TWR, e entregam as aeronaves que aterrisam a TWR. Monitora e gerencia as aeronaves dentro da Área de Controle Terminal (TMA), com aproximadamente 85 Km de raio e 5 Km de altura nas mediações dos aeroportos, definidos pelo Comando da Aeronáutica, no contexto brasileiro (OLIVEIRA, 2003).
- O centro de controle de área (ACC): monitora e gerencia as aeronaves no espaço aéreo que contém as rotas aéreas (aerovias), recebendo as aeronaves dos APPs origem e entregando-as aos APPs destino.

Pelo fato do espaço aéreo ser grande e bastante complexo, estas áreas de controle são divididas em subáreas denominadas de setores. Estes setores podem estar inteiramente

no espaço superior, inferior, ou ambos, conforme a estrutura do espaço aéreo vigente. No Brasil existem os três casos.

Os setores que abrangem as áreas de controle terminal (dentro do espaço aéreo inferior) estão sob jurisprudência do controle de aproximação (APPs), sendo chamados de setores APP. Os setores que abrangem as aerovias no espaço aéreo superior e inferior estão sob jurisprudência do Centro de Controle de Área (ACCs), sendo chamados de setores ACC. Cada setor APP e ACC é gerenciado por um controlador de tráfego aéreo, profissional responsável por todas as aeronaves que ocupem o setor por ele gerenciado (CONTROLE DE VÔO, 2003). A figura 2.2 apresenta a visão de um trecho do espaço aéreo brasileiro, compreendendo as regiões de Belo Horizonte, Brasília, Rio de Janeiro e São Paulo.

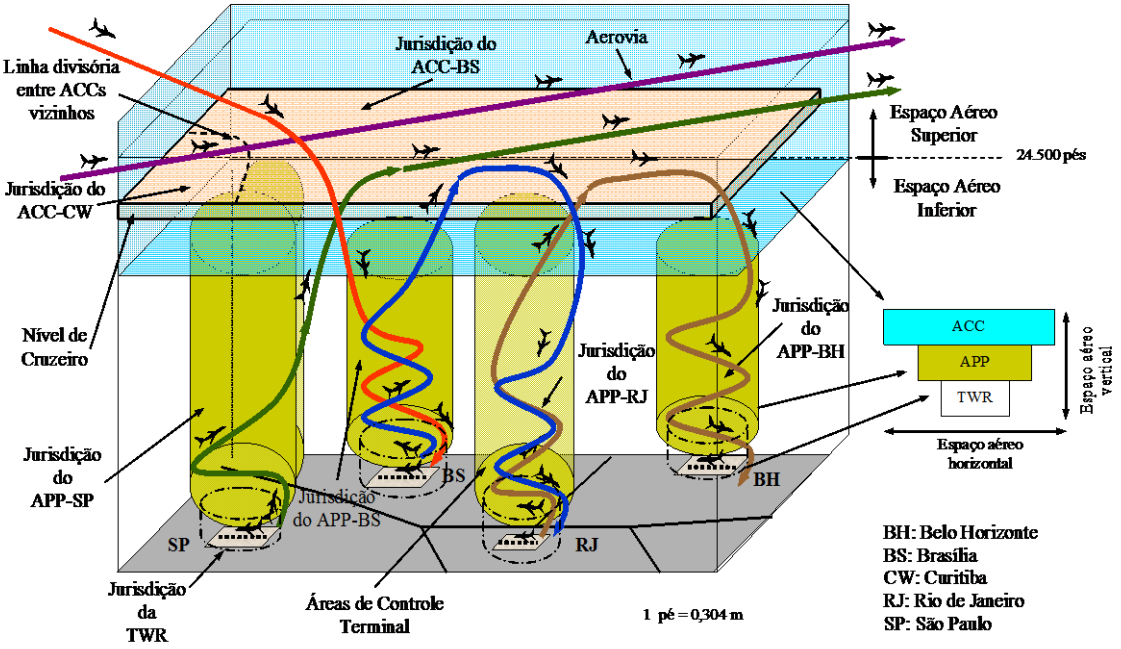

Figura 2.2: Visão de um trecho do espaço aéreo brasileiro

Em certas horas, quando o volume de tráfego aéreo é baixo, é comum que alguns setores APP e ACC sejam agrupados, passando, então, a serem monitorados por um único controlador de tráfego aéreo, que passa a prestar os serviços simultaneamente em dois ou mais setores. Isto pode ocorrer também em caso de falta de pessoal habilitado em número suficiente, o que certamente implica em redução da capacidade total de gerenciamento destes setores.

Durante um vôo o controle das aeronaves é transferido do APP origem, passando pelos ACCs, até o APP destino. A passagem de controle entre APP e ACC, e entre ACCs, é realizado através de um procedimento pré-estabelecido. Através deste procedimento é realizada uma notificação do ACC ou APP origem de que a aeronave será autorizada ou já foi autorizada a estabelecer contato com o ACC ou APP destino, com o objetivo de transferir o controle da aeronave.

O ACC ou APP destino notifica ao ACC ou APP origem, informando que estabeleceu contato com a aeronave transferida, e que assumiu o controle da mesma. Existem casos em que o tempo de cruzamento das aeronaves por um setor é tal, que não há tempo suficiente para aplicação do procedimento de transferência ao ACC intermediário, próximo responsável pela aeronave. Neste caso, é estabelecido um acordo que faculta a transferência de controle direta entre os ACCs, responsáveis pela aeronave. O controle da aeronave é transferido diretamente ao próximo ACC ou APP destino, sendo dado apenas ciência do tráfego ao ACC intermediário, que não recebeu o controle da aeronave.

As dimensões das áreas terminais, espaços aéreos e requisitos de separação entre aeronaves, tanto verticais, quanto horizontais são definidos através de normas internacionais, encontradas em (IMA 100-12, 1999).

Para garantir os serviços de controle de tráfego aéreo, cada aeronave deve periodicamente informar a sua posição. Esta atualização de sua posição pode ser feita, por exemplo, pela vigilância radar, ou então, ativamente pela aeronave, principalmente em regiões não cobertas por radares. Esta atualização é realizada entre controladores de tráfego aéreo e os comandantes das aeronaves.

O termo capacidade utilizado neste trabalho de pesquisa refere-se à capacidade ATC, sendo definida como a habilidade do sistema de controlar o tráfego aéreo e, em proporcionar serviço às aeronaves. Ela é expressa como o número máximo de aeronaves, em um setor do espaço aéreo, que podem ser gerenciáveis durante um período de tempo especificado (TARGA; ALVES; ARAUJO, 2001). Esta capacidade também é denominada de nominal ou declarada, sendo seu valor fornecido pelos órgãos responsáveis pelo controle de tráfego aéreo, que as determinam muitas vezes de forma

empírica, através da observação e experiência acumulada pelos profissionais responsáveis pelo gerenciamento de tráfego aéreo, por análises estatísticas do tráfego aéreo e atrasos gerados nos setores do espaço aéreo, entre outros recursos (RENTEX, 1998).

2.4 Fases de Planejamento do Controle de Tráfego Aéreo

O planejamento do fluxo do tráfego aéreo (ATFM - *Air Traffic Flow Management*) pode ser dividido em três fases distintas conforme a Eurocontrol - CFMU *(European Organization for the Safety of Air Navigation - Central Flow Management Unit*) (EATM, 2003); (LUTFARTSVERKET, 2001); (RAD, 2003] e (VERLHAC, 2001):

- Planejamento estratégico: durante o planejamento estratégico são realizadas atividades de pesquisas, levantamento de estatísticas, projeções e a coordenação de atividades de operação. Todas estas atividades são realizadas meses antes do dia efetivo da operação.
- Planejamento pré-tático: realiza atividades de mais curto prazo, incluindo ações de projeção de demanda e coordenação com companhias aéreas e órgãos de controle. Normalmente estas atividades são realizadas na véspera do dia da operação efetiva.
- Planejamento tático: as atividades nesta fase são realizadas no dia de operação, baseadas no planejamento das duas fases anteriores. Caso existam ainda problemas de congestionamento, não resolvidos nas fases anteriores, nesta fase são tomadas medidas de regulação no sentido de amenizar o desbalanceamento entre a capacidade da infra-estrutura aérea disponível e a demanda de tráfego aéreo existente.

2.5 Crescimento do Tráfego Aéreo

Como pode ser visto pela figura 2.3 (KNOEZER, 2003) e (SCHOFIELD, 2000) a tendência de aumento na taxa de crescimento do tráfego aéreo mundial é bastante elevada.

A demanda crescente do tráfego aéreo Mundial pode ser expressa em termos de número de movimentos de aeronaves nos aeroportos e no espaço aéreo.

Com o aumento do volume de demanda, surge a necessidade e a exigência de fornecimento de melhores serviços relacionados ao controle de tráfego aéreo. Sem esta melhora corre-se o risco das aeronaves não conseguirem mais realizar trajetórias otimizadas, que permitam consumo ideal de combustível e tempo de viagem, bem como a manutenção dos níveis de segurança (*safety*) aceitáveis.

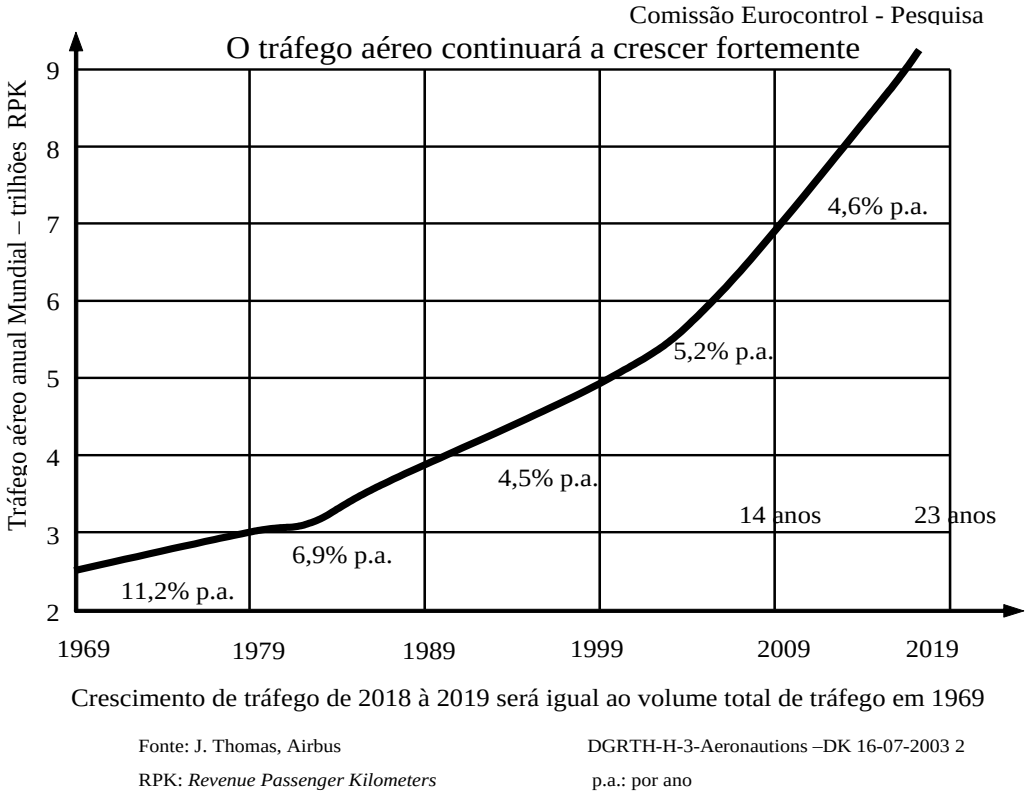

Figura 2.3: Taxa de crescimento de demanda Mundial

Para que tal fato não ocorra, pode ser necessário aumentar o número e intensidade dos atrasos dos vôos, tanto em solo, quanto em vôo, como forma de se manter os níveis de segurança atuais. A figura 2.4 apresenta uma estimativa dos atrasos totais, em aeroportos, e em rota, ocorridos semanalmente na Europa devido ao crescente aumento de tráfego aéreo (FCO.ET1.ST07.DEL02, 1998).

Existe uma pressão crescente da sociedade no sentido de se expandir à infra-estrutura aeronáutica existente, melhorando, por exemplo, a disponibilidade dos equipamentos de comunicação como radares, VORs (*Very High Frequency Omnidirectional Range*), etc.

Necessita-se também, de forma complementar, aumentar o número de profissionais ligados aos serviços de transporte aéreo, bem como melhor equipar os centros de controle de tráfego aéreos (ACCs e APPs), criar novos aeroportos etc. Igualmente, necessitam-se de pesquisas e desenvolvimento de novas tecnologias que permitam atender a crescente demanda de tráfego aéreo, de forma eficiente, mantendo-se a segurança (*safety*) em níveis aceitáveis.

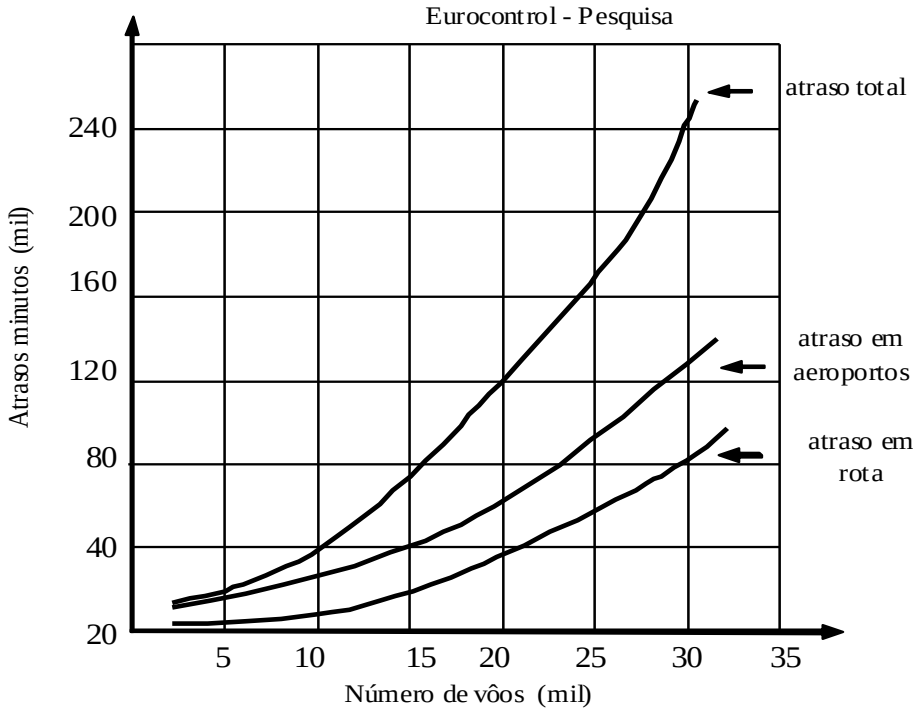

Fonte: ATM Estrategy 2000+, Eurcontrol Detaleid Delay Analyses
Maio 1998

Figura 2.4: Crescimentos de atrasos devido ao crescimento de demanda

A perspectiva deste crescimento também se deve em função do processo de desregulamentação do transporte aéreo mundial e a demanda reprimida por serviços de transporte aéreo em muitos países. Na verdade, existe uma pressão das grandes empresas multinacionais na tentativa de quebrar as reservas de mercado nacionais neste setor. De outro lado, as empresas nacionais tentam responder a essa pressão através da redução de suas tarifas aéreas, com o objetivo de atender a demanda interna reprimida e, ao mesmo tempo, enfrentar a possível concorrência internacional em seu mercado interno.

Essas mudanças trazem um grande impacto no sistema de transporte aéreo, que compreende desde o deslocamento, a partida e a chegada de aeronaves, os vôos em cruzeiro e as atividades dentro dos aeroportos. Também as categorias profissionais envolvidas na aviação civil são afetadas, desde aeronautas, aeroviários e controladores de tráfego aéreo.

A expansão da infra-estrutura aérea necessita de grandes investimentos, bem como um elevado período para implantação. Desta forma, corre-se o risco de que sempre a infra-estrutura aeronáutica esteja insuficiente, devido à tendência de elevadas taxas de crescimento do tráfego aéreo.

Assim, a adoção de novas tecnologias, que permitam utilizar de forma otimizada e eficiente a infra-estrutura aeronáutica já existente, torna-se uma opção interessante e fundamental para acomodar a crescente demanda de tráfego aéreo.

2.6 Carga de Trabalho de Gerenciamento dos Controladores de Tráfego Aéreo

O controlador de tráfego aéreo atua em salas de torres de controle em aeroportos, de radar, de controle de aproximação e de centro de controle de área. Ele é responsável pela comunicação com os pilotos por rádio, determina instruções que virão garantir a separação, a ordenação e a segurança do tráfego aéreo, nas proximidades dos aeroportos, nas rotas aéreas e nas transições de subidas e descidas.

Este profissional realiza tarefas complexas que exigem habilidades especiais, tais como, a aplicação de habilidades cognitivas, como a percepção espacial, processamento de informação, raciocínio e tomada de decisão. Estas atividades são extremamente desgastantes e estão no limite da capacidade de trabalho destes profissionais. A carga de trabalho (*Workload*) de gerenciamento inerente a esta atividade impõe, desta forma, níveis de estresse elevados, que necessitam serem aliviados, principalmente se for levada em consideração às projeções de aumento das taxas de demanda de tráfego aéreo.

O número de aeronaves simultâneas que um controlador de tráfego aéreo pode controlar depende de diversos fatores, tais como, tamanho dos setores, quantidade de tráfego dentro do setor, quantidade de tempo que o controlador já está trabalhando sem

descanso, o espaçamento entre aeronaves, número de auxílios a navegação que permita melhor precisão na localização das aeronaves dentro do espaço aéreo, entre outros.

Na verdade, o número de aeronaves que um controlador de tráfego aéreo consegue gerenciar simultaneamente é uma questão de grande controvérsia (SIEWERDT, 2003). Podem existir situações em que um setor pode possuir mais aeronaves simultâneas que a sua capacidade nominal declarada, apresentando facilidade em seu gerenciamento, desde que a separação mínima permitida entre as aeronaves esteja garantida. Por outro lado, podem existir situações que, com apenas 4 ou 5 aeronaves simultâneas, em setores de capacidade nominal declarada bem superiores a este número de aeronaves, podem gerar grande estresse. Este estresse pode ser devido à proximidade das aeronaves, próximo da separação mínima permitida, ou então, probabilidade de colisão futura entre as aeronaves. Embora existam muitos estudos e métodos de determinação de capacidade do controle de tráfego aéreo (ATC) atualmente publicados, ainda não se chegou a um consenso comum (SIEWERDT, 2003).

Espera-se que a pesquisa, o desenvolvimento e a adoção de novas ferramentas de automação do gerenciamento do tráfego aéreo tragam melhorias significativas, auxiliando os controlador de tráfego aéreo em suas inúmeras tarefas.

De forma a facilitar o entendimento dos efeitos dos atrasos e congestionamentos nos setores, pode-se identificar um efeito denominado de “efeito avalanche”. Neste caso, como o congestionamento de aeronaves dentro dos setores gera atrasos, estes, por sua vez, geram mais congestionamento e assim sucessivamente.

Em situações extremas, em que problemas de desbalanceamento não podem ser evitados, mesmo através das fases de planejamento do tráfego aéreo, o planejamento do fluxo do tráfego aéreo (ATFM) pode tomar algumas ações restritivas como, por exemplo, as listadas a seguir (TARGA; ALVES; ARAUJO, 2001):

- Atraso em solo (*ground-delay*): as aeronaves decolam após o seu horário programado.
- Atraso em vôo (*air-delay*): as aeronaves ficam retidas em vôo, aterrisando após o seu horário programado.

- Mudança de rota (*re-routing*): as aeronaves são desviadas para rotas alternativas, de maior custo.
- Regulagem da razão de fluxo em pontos específicos: através da medida (*metering*) e controle do fluxo de aeronaves em pontos considerados como mais críticos dentro da infra-estrutura aeronáutica.
- Restrição de velocidade das aeronaves: em pontos específicos da infra-estrutura aeronáutica, permitindo assim um melhor gerenciamento do fluxo de tráfego aéreo.

Dependendo do caso, pode ser aplicada uma destas medidas, ou então, uma combinação das mesmas.

2.7 Posicionamento da Pesquisa

Este trabalho de pesquisa propõe a otimização da utilização do espaço aéreo, incluindo o processamento de tempos em solo quanto em vôo das aeronaves. A abordagem apresentada pode ser uma alternativa interessante em termos de segurança (*safety*), bem como, em relação ao custo/benefício, quanto comparada à outras soluções atualmente utilizadas, como por exemplo, em relação à utilização de *slots time* em aeroportos.

Desta forma, este trabalho de pesquisa propõe um Modelo de Otimização de Demanda (MOD) em infra-estrutura aeronáutica, baseado em computação evolutiva, mais precisamente em algoritmos genéticos, um campo de pesquisa dentro da área de sistemas complexos. O conceito de sistema complexo é detalhado no capítulo seguinte.

Neste capítulo são apresentados aspectos conceituais relacionados a sistemas complexos, e sua relação com o contexto biológico.

3 SISTEMAS COMPLEXOS

> *"Complex is a word of the times, as in the often-quoted "growing complexity of life". Science has begun to try to understand the complexity in nature, a counterpoint to tradicional scientific objective of understanding the fundamental simplicity of laws of nature. It is believed, however, that even in the study of complexity there exist simple and therefore comprehensible laws. The field of study of complex systems holds that the dynamics of complex systems are founded on universal principles that may be used to describe disparate problems ranging from particle physics to the economics of societies.*
>
> Yanner Bar-Yam, Dynamics of Complex Systems, 1997

O cérebro humano apresenta aproximadamente 10^{12} neurônios e 10^{15} conexões entre eles (NIMH, 2000), que podem gerar padrões de comportamento extremamente complexos. Esta complexidade é de difícil representação pelos computadores mais avançados. Esta dificuldade não esta associada a uma simples análise de um subconjunto de neurônios, e suas respectivas conexões, mas devido ao elevado número de alternativas que podem ser encontradas por todas as associações de neurônios e suas conexões, determinando o comportamento global dos seres humanos. Dentro desta perspectiva, o cérebro humano pode ser considerado um sistema extremamente complexo, composto de uma rica associação de neurônios e interconexões (FOX; CODDINGTON, 1994).

Outro fator que torna o cérebro humano um paradigma em termos de complexidade é que as funções cerebrais que definem a cognição, tais como, mecanismos relacionados à associação, memorização, percepção e inferência, estão distribuídos dentro do cérebro e podem variar de indivíduo para indivíduo. Este fato torna ainda mais complexas as

atividades de compreensão e modelagem destes mecanismos em sistemas computacionais que procuram estudar a forma humana de resolução de tarefas e problemas.

De forma similar, a mesma análise pode ser aplicada a diversas áreas do conhecimento humano, principalmente naquelas que procuram determinar os princípios gerais que governam um determinado padrão de formação e organização (DAVIDSON; TEICHER; BAR, 1997). Este fato ocorre em diversos sistemas, desde biológicos, químicos, físicos, matemáticos, em engenharia e, até mesmo, em áreas econômicas e sociais. Este tipo de pesquisa vem apresentando grande interesse e atenção nos últimos anos devido a sua vasta aplicabilidade. Um dos principais fatores reside na busca de princípios gerais, que possam ser aplicados indistintamente a diversas áreas do conhecimento humano.

Os sistemas complexos são sistemas constituídos de partes interconectadas ou combinadas. Para se entender o comportamento de um sistema complexo, do ponto de vista qualitativo, deve-se entender não somente o comportamento de suas partes, mas também conhecer como estas partes interagem entre si de formar a determinar o comportamento do todo.

Assim, não se pode descrever o todo sem antes descrever cada uma de suas partes, e cada parte deverá ser descrita em relação às outras partes constituintes, ou seja, estes sistemas não são simples de serem compreendidos e analisados.

Outro fator importante, é que estes sistemas interagem dinamicamente com o seu ambiente, modificando-se em função deste. Esta característica aumenta ainda mais a complexidade destes sistemas, bem como a análise e a obtenção de respostas dos problemas a eles associados.

Outra forma de interpretar o significado de sistemas complexos, e que demonstra a dificuldade em quantificá-lo, é através do conceito que distingue os padrões abstratos não observáveis (microscópicos) e observáveis (macroscópicos). Através deste conceito a avaliação da complexidade de um sistema ou ambiente, está associada à capacidade de distinção de padrões que um particular observador consegue determinar (BAR, 2002). Neste caso, a medida da complexidade está associada à quantidade de informações observáveis que consiga descrever o comportamento global do sistema ou ambiente.

Desta forma, um particular observador que avalia um sistema ou ambiente, considera somente os padrões observáveis que ele pode distinguir. Esta forma de conceituação acaba fornecendo uma quantificação aproximada da complexidade de um sistema. Na verdade, ela fornece apenas uma medida da experiência humana em relação à complexidade.

Uma forma de demonstrar a necessidade de uma melhor quantificação da complexidade está no fato que existem propriedades microscópicas, que não podem ser explicitamente atribuídas às interações entre elementos. Estas propriedades não são ainda bem compreendidas, sendo fundamentais para uma melhor compreensão e quantificação da complexidade.

Uma característica importante é que muitos sistemas complexos apresentam uma grande dificuldade em definir e identificar todas as suas variáveis, bem como determinar o seu comportamento global.

Muitos dos sistemas que nos rodeiam na vida real são complexos. Este fato motiva o entendimento e investigação de suas propriedades cientificamente. Existe uma grande variedade de sistemas e fenômenos considerados como complexos, sendo investigadas as leis gerais para o seu entendimento. Estas leis gerais são também denominadas de "blocos construtivos" (*building blocks*) pois fornecem o "alicerce" à ciência (ADVANCES IN COMPLEX SYSTEMS, 2003).

A seguir são apresentados alguns conceitos fundamentais aplicados a sistemas complexos em engenharia, mais especificamente em computação, pois os mesmos são importantes na abordagem deste trabalho de pesquisa.

3.1 Conceitos Básicos

Os conceitos relacionados a problemas, tarefas, algoritmos, complexidade computacional e funcional, são essenciais para a compreensão de sistemas complexos. Estes conceitos são apresentados a seguir.

3.1.1 Sistemas e Tarefas Complexas

Um caminho para se identificar uma tarefa complexa é através do mapeamento entre o problema e a tarefa que o representa, ou então, as partes ou componentes do problema

que esta tarefa representa. Desta forma, existe uma relação direta entre problemas e tarefas complexas.

Uma tarefa complexa corresponde a um problema onde o número total de possibilidades distintas, que devem ser consideradas, é substancialmente maior do que a forma com que elas podem ser nomeadas ou enumeradas (BAR, 2002).

O grande número de possibilidades a serem tratadas mostra a necessidade de desenvolvimento de novas formas e estratégias de tratamento de inúmeros problemas. Normalmente, a simplificação de uma tarefa complexa, ignorando a possibilidade de diferentes respostas para o problema, pode conduzir a graves erros e falhas. A pior situação ocorre quando a resposta da tarefa, não leva em consideração os riscos que podem conduzir a elevados prejuízos humanos e financeiros.

Uma forma de interpretar tarefas complexas é através de sistemas complexos. Os sistemas complexos são sistemas com partes interdependentes. Esta interdependência significa que não se pode identificar o comportamento da tarefa, considerando isoladamente cada uma de suas partes integrantes, e sim compreendê-la pela combinação e análise de suas partes em conjunto.

3.1.2 Complexidade Funcional

Segundo (BAR, 2002) a complexidade funcional para um sistema pode ser composta por variáveis de entrada que apresentam complexidade $C_{(e)}$, e ações a serem tomadas pelo sistema que apresentam complexidade $C_{(a)}$. A complexidade funcional $C_{(f)}$ do sistema é definido por:

$$C_{(f)} = C_{(a)}\ 2^{C_{(e)}} \quad \text{(equação 1)}$$

Observe pela equação 1 que a complexidade funcional $C_{(f)}$ é definida em função do logaritmo de base 2 do número de possíveis entradas para o sistema. Este fato faz com que a complexidade funcional cresça de forma abrupta em função do número de variáveis de entrada.

O teorema ou princípio de complexidade funcional pode ser aplicado tanto a sistemas físicos, quanto a biológicos, sociais e em engenharia. Similar às leis físicas, ele relaciona as variáveis que caracterizam o sistema, seu contexto e suas ações.

3.1.3 Algoritmos e Problemas

Problemas em computação têm um significado preciso, e relacionam-se ao conceito de algoritmo. Assim, pode-se dizer que um algoritmo define um problema. Um algoritmo recebe dados de entrada, relacionados ao problema, e fornece dados de saída, que representam as respostas ao problema formulado. As entradas e as saídas formam o elo de ligação, entre o problema e o seu respectivo algoritmo.

Um problema pode ser definido por dois elementos (FALKENAUER, 1999):

Instâncias*:* lista exaustiva de todos os dados de entrada de um algoritmo.

Questão*:* lista exaustiva de todos os dados que podem ser a saída do algoritmo, ou seja, a resposta ao problema formulado.

De forma geral, o conceito de problema pode ser classificado da seguinte forma (FALKENAUER, 1999): Problemas de decisão, de contabilização e de otimização.

Nos problemas de decisão, deseja-se saber simplesmente se existe um dado que satisfaça um determinado critério. Em um problema de contabilização deseja-se saber quantos dados distintos satisfazem um determinado critério. Em um problema de otimização, deseja-se saber quais são os dados que satisfazem um determinado critério. O presente trabalho de pesquisa está intimamente relacionado a problemas de otimização.

3.1.4 Complexidade de Algoritmos e Problemas

A forma de conceituar complexidade de um algoritmo é através da definição de passo de um algoritmo, sendo este igual ao tempo de computação de uma instrução. O tempo de complexidade de um algoritmo corresponde ao número total de passos, necessários para o seu processamento.

A complexidade de um algoritmo também é função do tamanho do conjunto de dados de entrada. Quanto maior o espaço de pesquisa (conjunto de dados de entrada), maior será o tempo de execução do algoritmo.

A complexidade de um algoritmo e de um problema são dois conceitos distintos, podendo ser definidos como (FALKENAUER, 1999):

- A complexidade de um algoritmo é o maior tempo requerido pelo algoritmo para resolver um problema de um tamanho conhecido. Isto significa, em particular, que a

complexidade é medida em termos de pior caso, ou seja, a pior instância que o algoritmo possa ser submetido.

- A complexidade de um problema é definido pela complexidade do melhor algoritmo que o resolva, ou seja, um problema é tão complexo, tanto quanto for o melhor algoritmo conhecido que o resolva.

3.2 Problemas, Modelos e Simulações Computacionais

Um problema pode ser definido como uma situação em que se deseja alguma coisa e não se sabe de imediato como consegui-la (FREGNI, 1997). Normalmente é aquilo que é difícil de se explicar ou resolver, necessitando de uma seqüência de iniciativas ou ações que devem ser estudadas e executadas de forma a solucioná-lo.

A figura 3.1 apresenta a relação entre problema e sistema, sendo baseada na metodologia para o desenvolvimento de sistemas baseado em conhecimento (KADS – *Knowledge Acquisition and Documentataion Structuring*), que apresenta uma proposta de classificação pela Universidade de Amsterdam (FREGNI, 1997) e (SCHREIBER; WIELINGA; BREUKER, 1993).

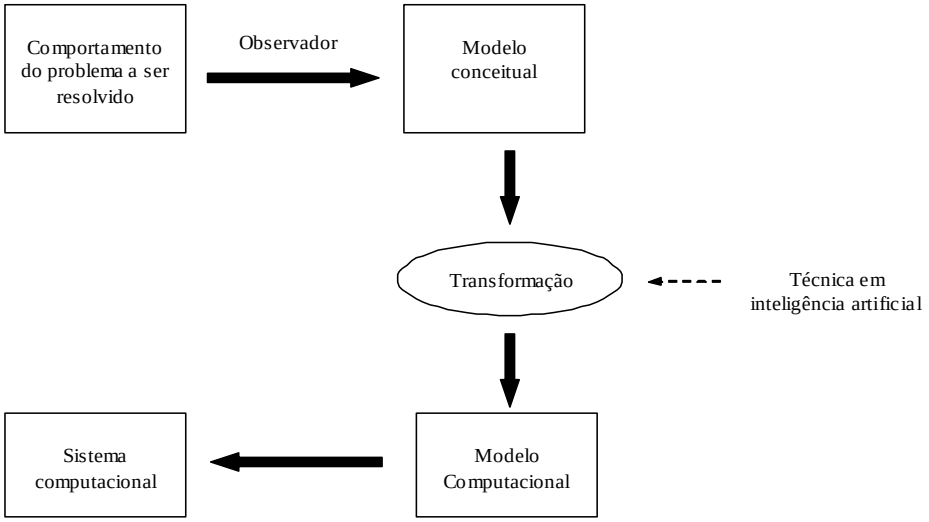

Figura 3.1: Relacionamento entre problema, modelo e sistema

Um observador pode elaborar um modelo conceitual baseado no conhecimento obtido através de um especialista humano, do problema em questão. Este especialista descreve o comportamento ou o modo de solução deste problema, que é transferido ao modelo

conceitual. Este modelo conceitual, mais genérico, pode ser transformado em um modelo computacional através, por exemplo, de técnicas de inteligência artificial. Este modelo computacional apresenta maior detalhamento e pode ser representado em um sistema computacional. Este sistema pode ser simulado e apresentar as respostas (soluções) para o problema analisado.

Um sistema pode ser definido como complexo, dentro da perspectiva computacional, se o problema e seu respectivo modelo computacional forem complexos. Neste caso, adota-se uma técnica heurística de solução, ou seja, o algoritmo computacional utilizado pelo sistema computacional é um algoritmo de otimização. A figura 3.2 apresenta, de forma esquemática, tal caracterização.

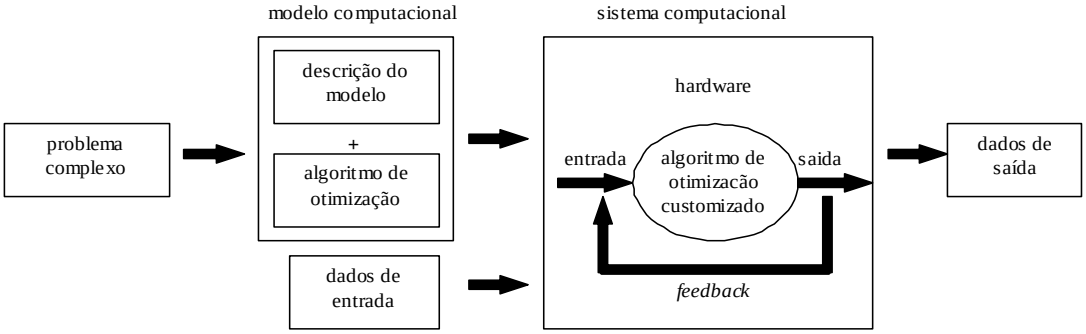

Figura 3.2: Sistema complexo do ponto de vista computacional

Um problema complexo pode ser mapeado em um modelo computacional dividido em dois componentes básicos. O primeiro é a descrição do modelo que o representa de forma algorítmica, e o segundo é o algoritmo de otimização propriamente dito. A descrição do modelo e o algoritmo de otimização apresentam uma sinergia, no sentido de que o primeiro modela a forma com que o segundo irá se comportar, gerando-se um algoritmo de otimização customizado para o problema. Uma característica importante do algoritmo de otimização customizado, advinda dos algoritmos de otimização, é o fenômeno de *feedback*, que direciona o processo de otimização.

Observe que o mapeamento de um problema em um modelo normalmente resulta em perda de informação, seja por desconhecimento, falta de informação, ou propositalmente, de forma a simplificar a otimização. Como pode ser observado na

figura 3.2, um sistema complexo, do ponto de vista computacional, é representado por um sistema computacional contendo um algoritmo de otimização.

3.3 Sistemas Complexos e a Biologia

A biologia apresenta atualmente uma abordagem baseada na observação e necessidade de grandes quantidades de informação, que devem ser procuradas, acumuladas e interpretadas, tanto em relação a elementos individuais, quanto a agrupamentos coletivos. Individualmente, os sistemas biológicos podem ser vistos como grandes redes bioquímicas intrincadas e espacialmente estruturadas.

Estas grandes quantidades de informação, bem como os comportamentos coletivos biológicos, seus relacionamentos, estruturas e funções estão sendo explorados por matemáticos, físicos e engenheiros. Os biólogos necessitam, cada vez mais, de tecnologias avançadas visando atender às diversas necessidades de suas pesquisas. Já os engenheiros observam e analisam cada vez mais os sistemas biológicos como uma forma de inspiração para serem utilizados em seus projetos.

3.3.1 Organismos e seu Meio Ambiente

O estudo de organismo[1], seu comportamento e o processo de evolução, através de ferramentas matemáticas e computacionais é uma das áreas que vem crescendo rapidamente, tornando-se fundamental no estudo de sistemas complexos. Uma das linhas de pesquisa, dentro de sistemas complexos, é o estudo da dinâmica evolucionária coletiva de indivíduos. O foco neste caso é a análise do comportamento coletivo, normalmente complexo, e a interação destes com seu meio ambiente.

Todo modelo de comportamento coletivo deve incluir o modelo do ambiente em que estes organismos estão inseridos. Este modelo deve levar em consideração as respostas dinâmicas a estímulos externos, bem como a relação entre as potencialidades dos organismos. A demandas exigidas pelo ambiente apresentam um papel fundamental na modelagem coletiva dos organismos.

A complexidade dos organismos e de seus ambientes está fortemente relacionada. Além do comportamento individual de cada organismo, é fundamental entender e descrever a

[1] Qualquer ser vivente, seja ele um animal, uma planta ou o próprio ser humano.

interação entre os organismos, que pode definir o comportamento coletivo. A interação entre organismos pode ser dada por relações de competição, cooperação, reprodução, parasitismo, comunicação, exploração, consumo, entre outros (LINHARES; GEWANDSZNAJDER, 1980, 1998).

Os modelos computacionais que utilizam os conceitos da biologia para resolução de problemas das mais diversas áreas têm como principal objetivo modelar os aspectos da dinâmica evolucionária das populações. Pode-se até adotar modelos completamente abstratos em relação ao comportamento dos organismos, e que não estejam diretamente relacionados à biologia. Estes modelos fornecem a percepção da dinâmica e das interações da população ao longo do tempo.

Estes modelos computacionais descrevem o comportamento das populações através de um conjunto de parâmetros que são considerados dentro do espaço de ocupação (meio ambiente) da população, e pelas características individuais de seus organismos. Estes modelos são estudados e voltados às teorias e conceitos da computação, principalmente as relacionadas à inteligência artificial.

3.3.2 A Teoria da Evolução

A teoria da evolução é um processo geral e dinâmico na formação de organismos complexos, através de mudanças incrementais ao longo do tempo, criado pelo inglês Charles Darwin. Os princípios fundamentais de sua teoria estão expressos em seu livro *The origin of species*, lançado em 1859 (BLANC, 1994). A evolução é um processo contínuo que produz organismos mais aptos e complexos ao longo do tempo. Assim, compreender os principais conceitos envolvidos na teoria da evolução, também permite identificar alguns conceitos gerais associados aos sistemas complexos.

O principal objetivo da teoria da evolução é explicar a origem e diversidade da vida na Terra. Tradicionalmente a evolução é dividida em duas partes: a primeira ligada à Variedade Genética no qual atua a Reprodução Sexuada influenciada pelos fenômenos da Permutação e Mutação; a segunda em relação à Seleção Natural, no qual atuam os fenômenos de Aptidão e a Dinâmica da Melhoria Incremental. Esta separação é essencial para o entendimento da Teoria da Evolução, sendo melhor detalhada a seguir.

3.3.2.1 Variedade Genética

A variedade genética parte do princípio que, através da reprodução sexuada, produz-se uma grande variedade de organismos geneticamente diferentes, que herdam características de seus descendentes. Estas características herdadas são transmitidas aos seus descendentes ao acaso. Charles Darwin reconheceu a variedade entre as espécies, mas não conseguiu entender quais os fatores que produziam tal variedade, mais tarde descobertas pelo monge gregoriano Gregor Mendel, em 1866. A seleção natural não ocorre ao acaso, como acontece com a variedade genética, sendo determinada por fatores ambientais, fazendo com que os organismos mais adaptados sobrevivam.

A teoria da evolução é fundamental, pois fornece uma estrutura que permite compreender, em muitos aspectos, a dinâmica de muitos sistemas complexos. A complementação da pesquisa de Darwin ocorreu através da compreensão dos conceitos de gene, mutação e permutação. Desta forma a teoria de Darwin foi complementada dando origem ao termo chamado de neodarwinismo, conforme apresentado na figura 3.3.

Nesta visão a variabilidade genética tem como fatores determinantes a mutação e a permutação. Estes interferem diretamente na seleção natural, ou seja, na aptidão dos organismos ao meio onde vivem.

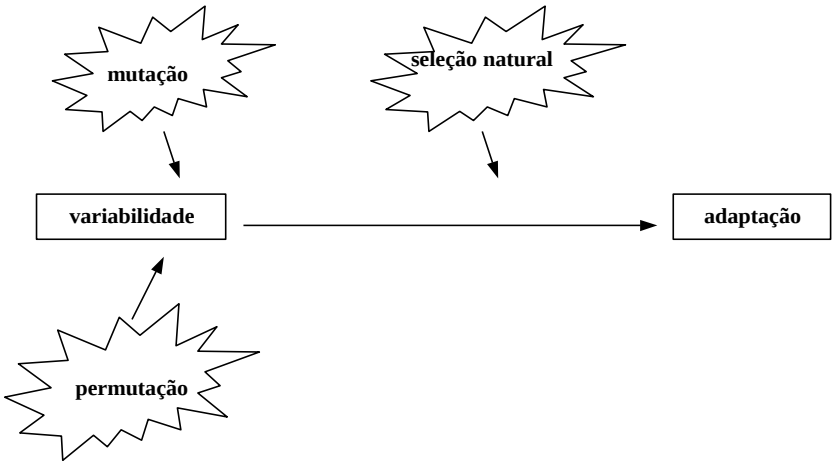

Figura 3.3: Visão geral do neodarwinismo

A reprodução sexuada aumenta a variedade genética que contribui para a maior adaptabilidade das espécies ao meio ambiente. Diferentemente, na reprodução assexuada os descendentes são idênticos aos ascendentes.

A maior variedade genética é devido a grande variedade cromossômica entre diferentes organismos de uma mesma população, que são associados ou combinados durante o processo de reprodução sexuada. A variedade genética foi melhor compreendida através da descoberta do modelo do ADN (ácido desoxirribonucléico) na década de 1950 por J. D. Watson e F. H. C. Crick.

Um organismo é composto por um número de fixo de cromossomos. Estes são responsáveis pela transmissão de suas características hereditárias a seus descendentes. Os cromossomos são formados por setores ou segmentos denominados de genes. Estes definem as características dos organismos, como cor de olhos, forma dos cabelos, existência de substâncias no sangue etc.

A constituição genética ou conjunto de material hereditário que um organismo transmite a seus descendentes é chamado de genótipo. O genótipo de um organismo em conjunto com o seu meio ambiente, definem o seu fenótipo, conjunto de características morfológicas ou funcionais que podem ser observadas.

Os cromossomos são formados por ADN (ácido desoxirribonucleico), sendo o gene um setor da molécula do ADN. Este é formado por uma seqüência de estruturas que possuem quatro tipos de bases nitrogenadas, denominadas de Timina (T), Citosina (C), Adenina (A) e Guanina (G). Estas são pareadas duas a duas dentro da cadeia de um ADN (ANGLO, 1990). Assim, o ADN é uma longa cadeia composta por diversas moléculas, que podem ser decompostas em bases, e estas decompostas em átomos. Uma pequena alteração ou troca de uma posição destas bases numa longa cadeia de ADN pode modificar as características de um organismo, podendo alterar seu genótipo, fenótipo e a seleção natural deste organismo dentro de sua população[1].

[1] Organismos da mesma espécie (raça) que ocupam a mesma área ou habitat

Assim, como no alfabeto português existem 23 letras que podem armazenar e transmitir todo o conhecimento humano, estas quatro substâncias químicas podem escrever e transmitir todas as características dos organismos. Como existem praticamente inúmeras possíveis alterações para as bases nitrogenadas, podem também alterar o genótipo e o fenótipo (ETAPA, 1991).

A análise destas alterações de bases nitrogenadas e a conseqüente influência no genótipo e fenótipo são extremamente complexas.

Sobre a reprodução sexuada ocorrem dois fenômenos essenciais descritos a seguir:

a) Permutação

Permutação é o tipo de herança em que dois ou mais pares de genes alelos (situados em cromossomos diferentes) atuam sobre uma mesma característica. Assim, a troca de genes entre os dois cromossomos homólogos (que apresentam a mesma forma e tamanho, ou seja, representam as mesmas características) ocorre nos mesmos locais (também denominado de *loci*), levando à formação de novas características para os organismos.

Os genes anteriormente ligados em um cromossomo se desligam, voltando-se a ligar a outro gene pertencente à mesma posição (também denominado de *locus*) do outro cromossomo. Há um troca de genes entre os cromossomos.

Na permutação, como pode ser visto na figura 3.4, apesar dos cromossomos descendentes (filhos) serem diferentes dos cromossomos ascendentes (pais), cada cromossomo descendente recebe em seus genes uma parte de cada um dos seus cromossomos ascendentes. Assim, os cromossomos ascendentes *Aa* e *Bb*, geram os cromossomos descendentes *Ab* e *Ba*.

Figura 3.4: Modo de ocorrência da permutação

A permutação é um fenômeno quase universal na biologia (LINHARES; GEWANDSZNAJDER, 1998), sendo raro os organismos que tal processo não ocorre. Um exemplo deste caso é a reprodução assexuada. Deve ser observado que a posição dentro do cromossomo, na qual ocorre a permutação, é selecionada ao acaso. A permutação pode também ocorrer em mais de uma posição dentro de um mesmo cromossomo.

Importante frisar que na permutação os organismos apresentam apenas as características já existentes em seus ascendentes, ou seja, nunca há o surgimento de novas características. A grande vantagem da reprodução sexuada é a ampla variedade de organismos produzidos, pois o número de variantes cromossômicos pode ser ilimitado, dependente do tamanho e número de genes presentes no cromossomo.

b) Mutação

Imagine que no momento da duplicação do ADN, ocorra um erro de cópia que altere a sua seqüência, e que por conseqüência altere o material genético do organismo. Assim, o genótipo do organismo é alterado, e esta alteração pode ser transmitida posteriormente a seus descendentes. Este fenômeno é definido como mutação. A mutação pode ser gênica, quando um ou mais genes são alterados, ou cromossômica, quando a alteração ocorre na estrutura ou no número de cromossomos. A figura 3.5 apresenta o efeito da mutação gênica. Observe-se que no processo de mutação os cromossomos ascendentes *Aa* e *Bb* geram os cromossomos descendentes *AC* e *Ba*.

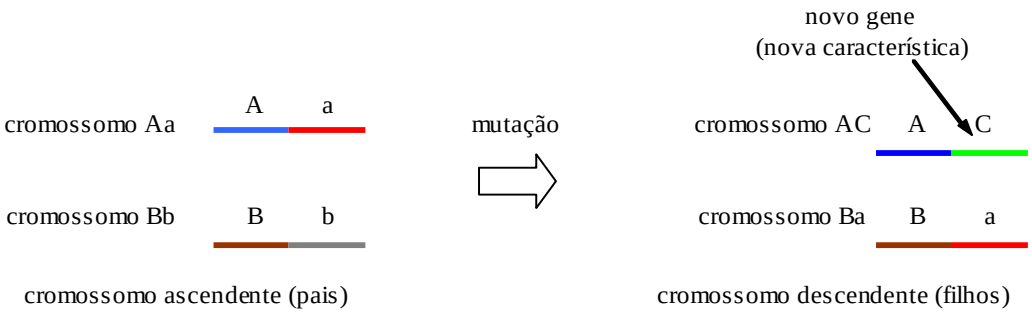

Figura 3.5: Modo de ocorrência da mutação

O cromossomo descendente A*C* apresenta um gene novo *C*, que não existia anteriormente em seus cromossomos ascendentes. Assim, esta nova característica pode ser transmitida aos futuros descendentes.

A mutação é um fator importante para a geração de novas características nos organismos. A mutação é fundamental pois aumenta, ainda mais, a variedade genética dos organismos através de características anteriormente não presentes em seus ascendentes. Estas novas características podem interferir diretamente no processo de seleção natural.

Na natureza a mutação é um processo raro e espontâneo, podendo ser provocada por certas condições do meio ambiente (LINHARES; GEWANDSZNAJDER, 1998). A mutação pode gerar organismos mais ou menos adaptados, ou seja, as características são geradas de forma aleatória. As mutações vantajosas são transmitidas aos organismos descendentes mais aptos, e as mutações prejudiciais produzem indivíduos menos aptos, sendo eliminados pela seleção natural.

3.3.2.2 Seleção Natural

A seleção natural impõe uma ordenação ao processo evolutivo, privilegiando os organismos mais adaptados e eliminando os menos adaptados. Os organismos mais adaptados tendem a se reproduzir e gerar descendentes, capazes de também se reproduzirem, podendo gerar organismos mais adaptados ao ambiente onde vivem.

A teoria de seleção natural elaborada por Charles Darwin foi baseada em duas hipóteses, obtidas através de suas observações ao longo do tempo, que levaram posteriormente a duas conclusões (teses) consideradas fundamentais (SHORROCKS, 1978) apresentadas a seguir:

Hipóteses:

1) A variação dos organismos sob a forma de diferenças individuais, existente em todas as espécies e populações, é explicada através da variedade genética.
2) Todos os organismos produzem descendentes em número muito maior do que aquele que sobrevive até a idade reprodutiva.

Teses:

1) Existe um processo de competição pela sobrevivência, no qual os organismos mais adaptados tendem a sobreviver, e os menos adaptados tendem a serem eliminados.
2) As características dos organismos que são favorecidas pelo processo de competição são transmitidas de geração a geração, através de um processo de melhoria incremental.

Estas duas teses levaram a identificação de fenômenos fundamentais na seleção natural: aptidão e dinâmica da melhora incremental.

a) Aptidão

A aptidão ou adaptabilidade é a propriedade fundamental na dinâmica dos organismos, pois através dela um organismo se perpetua e sobrevive em seu meio ambiente. A aptidão é o critério utilizado na seleção natural para selecionar quais os organismos mais aptos sobreviverão. Charles Darwin descobriu que o mecanismo de evolução biológica correspondia ao processo de seleção natural, e que este processo nada mais era do que a sobrevivência dos mais aptos. Os organismos que não se adaptam ao longo da cadeia evolutiva são extintos, ou seja, existe um processo de seleção. Os organismos mais aptos são capazes de reproduzir e perpetuar a sua espécie.

Os indivíduos são imbuídos de uma única missão, ou seja, manter-se vivos pelo tempo suficiente para produzir cópias de si próprios. Para manterem-se vivos e reproduzir, os organismos necessitam de um fluxo contínuo de energia, obtidos através da alimentação, de condições atmosféricas adequadas para a sua sobrevivência e produção de alimentos, da pouca existência de predadores entre outros. Assim, o meio ambiente é um fator decisivo na aptidão dos organismos. Todos estes fatores são relevantes e determinantes na seleção natural.

b) Dinâmica da Melhora Incremental

A Teoria da Evolução é baseada fundamentalmente nos processos básicos de mutação e seleção natural. A mutação causa mudanças incrementais nos organismos, de geração a geração, ao longo do tempo, de forma gradativa durante todo o processo de seleção natural.

Uma forma de ilustrar a dinâmica da melhora incremental através dos processos de mutação e seleção natural é através de um caso particular, no qual não ocorre mudança populacional, ou seja, não ocorre migrações de organismos de geração a geração para outras populações. Este caso particular é chamado de equilíbrio populacional (BAR, 1997). Imagine uma população de organismos que apresente a distribuição de sua população através de uma distribuição Gaussiana em função de uma propriedade hereditária, que interfere de forma positiva na aptidão de seus organismos. Esta propriedade hereditária torna os organismos mais aptos a sobreviverem em seu ambiente.

A figura 3.6 (BAR, 1997) ilustra conceitualmente o equilíbrio populacional resultante dos processos de mutação e seleção natural sobre uma população isolada.

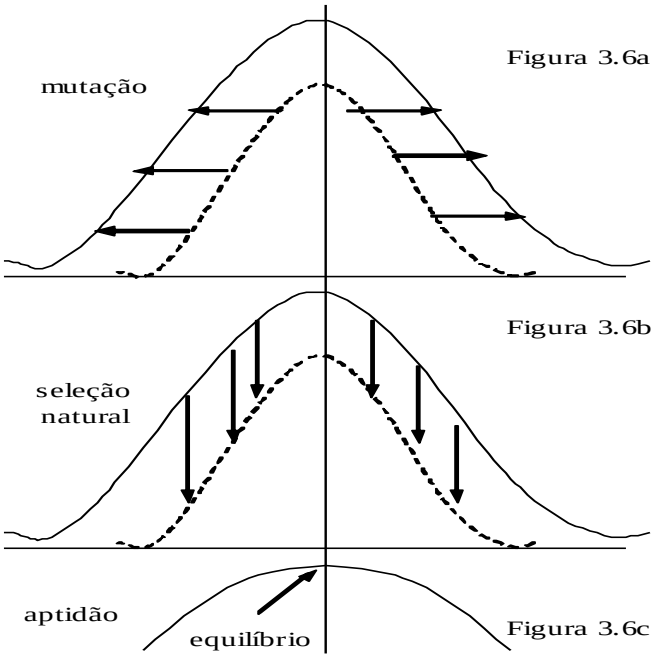

Figura 3.6: Equilíbrio em uma população

A figura 3.6a apresenta o aumento na diversidade populacional em conseqüência da ação da mutação. A figura 3.6b apresenta a diminuição na diversidade populacional devido à ação da seleção natural. Quando estes processos estão equilibrados, não há nenhuma mudança significativa na distribuição populacional. O eixo horizontal corresponde a propriedade hereditária favorável a adaptação dos organismos, e o eixo vertical é a

distribuição populacional. A figura 3.6c ilustra a variação da aptidão com a propriedade hereditária. Em função disto, o equilíbrio ocorrerá no ponto mais elevado desta curva.

Neste contexto, o processo de evolução ocorre de forma incremental, através do deslocamento da curva de distribuição da população ao longo da coordenada horizontal, conforme ilustrado na figura 3.7 (BAR, 1997).

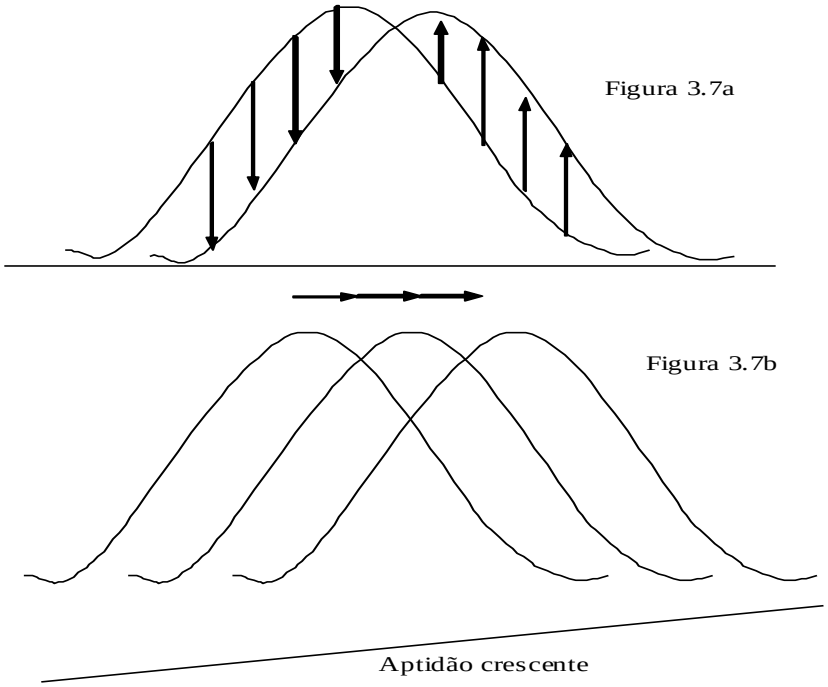

Figura 3.7: Dinâmica do processo de evolução

A figura 3.7a apresenta a ação do processo de seleção natural. A figura 3.7b apresenta o deslocamento da distribuição populacional ao longo do tempo. Observe que este deslocamento é direcionado por valores crescentes de aptidão, relacionado a propriedade hereditária favorável, que orienta o processo de evolução. Assim, pode-se entender a evolução como este deslocamento da distribuição populacional ao longo do tempo.

Neste contexto, a permutação aparece como um elemento secundário, que determina a velocidade de deslocamento desta distribuição ao longo do tempo. A permutação determina a velocidade de disseminação de novas características favoráveis a adaptação dos organismos, geradas pela mutação, e transmitidas aos organismos descendentes durante a evolução (BAR, 1997).

A filosofia por trás da teoria da evolução motiva e envolve a criação e utilização de modelos computacionais. Estes modelos devem realizar um paralelo entre os conceitos de espaço de representação, em que os organismos estão envolvidos, bem como a aptidão durante o processo de seleção natural. Assim, os modelos computacionais criados devem estar associados ao genótipo e fenótipo dos organismos, que podem ser modificados pela reprodução, através dos processos de permutação e mutação.

Desta forma, os modelos computacionais reproduzem os princípios básicos da teoria da evolução, em um sistema de "evolução acelerada", levando horas, minutos ou até segundos, fenômeno este que na natureza levou milhões de anos para trazer diferenças significativas entre os diversos organismos existentes.

A teoria da evolução, com base nos conceitos de diversidade populacional e seleção natural, pode ser vista como leis gerais a serem investigadas dentro do contexto de sistemas complexos. No próximo capítulo são apresentadas as principais características da computação evolutiva, com foco em algoritmos genéticos, técnica de otimização utilizada neste trabalho de pesquisa.

Este capítulo apresenta as principais características da computação evolutiva, com foco especial em algoritmos genéticos, a principal técnica de otimização abordada neste trabalho de pesquisa.

4 COMPUTAÇÃO EVOLUTIVA E ALGORITMOS GENÉTICOS

"Optimization is the process of making something better. An engineer or scientist conjures up a new idea and optimization improves on that idea."

Randy L. Haupt e Sue Ellen Haupt,
Pratical Genetic Algorithms,1998

As origens da computação evolutiva podem ser traçadas desde a década de 1950, e pode-se dizer que ainda são relativamente desconhecidas pela grande maioria da comunidade científica (SCHWEFEL; HAMMEL; BÄCK, 1997). Mas, o número de publicações vem crescendo em número e qualidade nos últimos anos, tornando esta área um grande campo de pesquisas. Basta observar iniciativas como a criação de grandes publicações, tais como, *IEEE Transactions on evolutionary computation* (IEEE *TRANSACTIONS ON EVOLUTIONARY COMPUTATION*, 2004) e, a *International Conference on Parallel Problem Solving from Nature (PPSN)* (INTERNATIONAL CONFERENCE PPSN, 2004).

Basicamente, a computação evolutiva é uma grande área relacionada a técnicas de otimização e pesquisa, que encontra as suas origens e inspiração no mundo da biologia (TOMASSINI, 1996). A partir da teoria de evolução de Darwin, que apresenta como fundamento a sobrevivência dos seres mais aptos em um ambiente dinâmico, a teoria evolucional é amplamente aceita, principalmente pelas evidências acumuladas durante milhões de anos em nosso planeta. Em computação evolutiva, os operados genéticos permutação, mutação e o processo de seleção natural procuram imitar os seus correspondentes da natureza.

Os principais fatores motivadores do crescimento e esforço em pesquisas na área de computação evolutiva estão relacionados ao seu paralelismo intrínseco, flexibilidade,

adaptabilidade, grande robustez em termos de desempenho, e às suas características de pesquisa global. De uma forma geral, computação evolutiva pode ser entendida como um conceito geral e adaptável para a solução de problemas, especialmente aqueles relacionados a problemas de difícil otimização (*hard optimization problems*).

A grande maioria das implementações da computação evolutiva estão relacionadas a três abordagens independentes: algoritmos genéticos, programação genética e estratégias de evolução (SCHWEFEL; HAMMEL; BÄCK, 1997). Outras abordagens, tais como, programação evolucional e sistemas classificadores, também merecem destaque devido ao crescente número de publicações, e ao seu potencial de pesquisas. A seguir é apresentada uma taxonomia da representação da inteligência humana. Esta classificação pode ser considerada uma das formas mais genéricas de abordar a computação evolutiva, bem como situá-la dentro do contexto científico.

4.1 Taxonomia de Representação da Inteligência Humana

Sempre o homem quis entender e, principalmente, definir modelos que permitissem reproduzir a inteligência humana de forma a transferi-los para os sistemas computacionais. Por outro lado, muitas destas tarefas computacionais são extremamente complexas, apresentando grande consumo de tempo e processamento computacional, conforme já apresentado no capítulo 3 - Sistemas Complexos. Mesmo utilizando supercomputadores modernos, que executam bilhões de operações por segundo, a resolução dos modelos computacionais de tais sistemas complexos nem sempre é possível de ser realizada em um tempo admissível, através de técnicas tradicionais de otimização.

Em algumas classes de problemas em que a solução aproximada já é suficiente, adotam-se normalmente técnicas heurísticas, também denominadas de aleatórias. Tais técnicas ou algoritmos otimizam a resolução de um problema através de uma solução aproximada.

Normalmente, o modelo correspondente à solução de tais problemas representa a forma de controle de um especialista humano, mais do que o modelo do sistema ou processo a ser controlado. Uma forma de diminuir esta complexidade computacional é caminhar no

sentido da representação artificial da inteligência humana, que controla tais sistemas ou processos, dando origem ao termo inteligência artificial (PATRIDGE; WILKS, 1990).

Entretanto, o significado de inteligência artificial é muito vago, e sua amplitude de significado cobre vários aspectos que necessitam de uma melhor compreensão e definição (HÄMÄLÄINEN, 1996). Desta forma, pode-se distinguir a representação da inteligência humana em dois campos: inteligência artificial e inteligência computacional.

A inteligência artificial (IA) pode ser caracterizada em um alto nível de abstração, em um ponto de vista macroscópico (MARKS, 1993). Por outro lado, a inteligência computacional (IC) é utilizada em um ponto de vista microscópico, similar ao fisiológico ou genético. Enquanto a inteligência artificial utiliza representação simbólica para o pensamento, a inteligência computacional utiliza a informação em formato numérico (HÄMÄLÄINEN, 1996).

O termo inteligência computacional pode-se ser utilizado indistintamente como *soft computing*, e foi utilizado pela primeira vez por Zadeh (ZADEH, 1994). Ele define *soft computing* como uma coleção de metodologias que objetivam explorar a tolerância, a imprecisão e a incerteza. O objetivo é facilitar o controle, robustez, bem como fornecer soluções de baixo custo. Em *soft computing* (KUYPER, 2000) e (ZADEH, 1994) definem-se como principais classes as redes neurais artificiais, a teoria dos conjuntos *fuzzy*, a computação evolutiva e a computação probabilística (ZADEH, 1997).

Cada uma destas classes pode ser subdividida em subclasses. A teoria dos conjuntos *fuzzy* pode ser subdividida em teoria dos grafos *fuzzy*, aritmética *fuzzy* e lógica *fuzzy* (ZADEH, 1994) e (ZADEH, 1997). A classe da computação evolutiva pode ser dividida em: programação evolucional, estratégias de evolução, programação genética, sistemas classificadores e algoritmos genéticos.

4.1.1 Conclusão da Taxonomia da Representação da Inteligência Humana

De um modo geral, existem diversas taxonomias da representação da inteligência humana, principalmente com referencia aos algoritmos genéticos paralelos, devido esta área de pesquisa estar em constante desenvolvimento. A taxonomia levantada neste trabalho de pesquisa está apresentada na figura 4.1. Ela é uma compilação das taxonomias apresentadas em (ALBA; TROYA, 1998); (ADAMIDIS, 1994, 1998);

(PAZ, 1995, 1995a, 1996); (THE FLYING CIRCUS, 2002); (NOWOSTAWSKI; POLI-99) e (WANG; MACIEJEWSKI; SIEGEL, 1998).

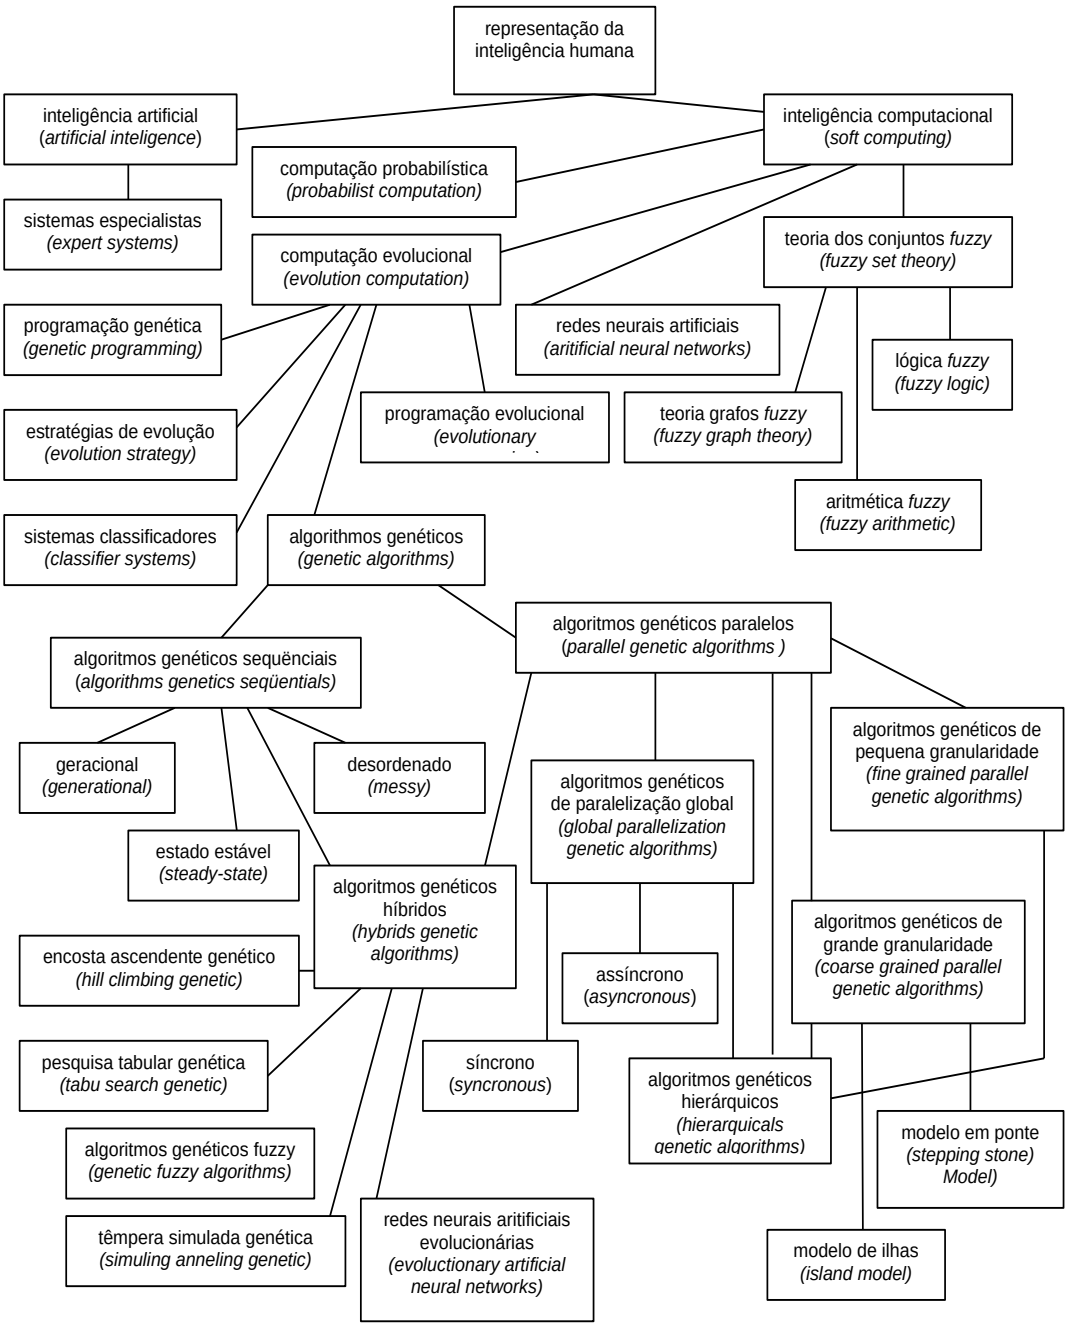

Figura 4.1: Taxonomia da representação da inteligência humana

Existem outras propostas como a de (WANG, 1997) que apresenta 5 classes de algoritmos genéticos paralelos: algoritmos genéticos paralelos independentes (*independents parallels genetic algorithms*), algoritmos genéticos paralelos migratórios

(*migrations parallels genetic algorithms*), algoritmos genéticos paralelos particionados (*partitioned parallels genetic algorithms*), algoritmos genéticos paralelos de segmentação (*segmentation parallels genetic algorithms*) e algoritmos genéticos paralelos de segmentação e migratório (*segmentation - migration parallels genetic algorithms*).

No capítulo 5 são detalhadas três implementações de algoritmos genéticos seqüenciais. Adicionalmente, também é detalhada a implementação de um algoritmo genético paralelo, mais especificamente, o modelo em ponte. Estes algoritmos genéticos foram selecionados como parte integrante do modelo de otimização de demanda proposto.

4.2 Algoritmos Genéticos (*Genetic Algorithms*)

Introduzido por (HOLLAND, 1961), propõem um modelo geral para a grande maioria das aplicações relacionadas às técnicas de otimização (SCHWEFEL; HAMMEL; BÄCK, 1997) e (GORDON; WHTLEY, 1996). Entre todas as técnicas da computação evolutiva, pode ser considerada a mais genérica, na qual o problema em análise é resolvido pela evolução e seleção dos mais aptos (FREGNI, 1997). As soluções são representadas por *strings* (seqüência de caracteres ou dígitos binários) de comprimento fixo e evoluem através de operadores genéticos, denominados de permutação e mutação (BANZHAF; REEVES, 1999).

Em algoritmos genéticos os conceitos de indivíduo, organismo e cromossomo são equivalentes e referem-se a possíveis soluções para um dado problema em análise. Assim, uma população em algoritmos genéticos é composta por um conjunto de cromossomos, sendo cada um deles representado através de uma cadeia de *strings* binários (*bits*). Cada conjunto destes *bits* e sua posição (*locus*) dentro da cadeia cromossômica, definem uma característica do organismo, sendo identificado como gene. O conjunto de genes de um indivíduo define o seu genótipo, ou seja, a sua carga cromossômica. Cada um dos possíveis valores que estes genes podem assumir é denominado de alelos. A função de aptidão, que direciona o processo de evolução, é a exteriorização do genótipo, também chamada de fenótipo do indivíduo.

Os Algoritmos Genéticos podem ser classificados como: algoritmos genéticos seqüenciais e paralelos, conforme apresentado a seguir:

4.2.1 Algoritmos Genéticos Seqüenciais

Os algoritmos genéticos seqüenciais atuam através de uma única população de cromossomos de comprimento fixo (PAZ, 1995a). Os cromossomos são representados por uma seqüência de *strings*, que codificam as variáveis do problema a ser otimizado. Seus operadores são definidos em três categorias: seleção, permutação e mutação. Os algoritmos genéticos seqüenciais podem ser divididos em três categorias:

a) Algoritmos Genéticos Geracionais (*Generational Genetic Algorithms*)

É a técnica clássica empregada em algoritmos genéticos (BENNET, 2000), descrito inicialmente por John Goldber em 1989, em seu livro "*Genetic algorithms in search and optimization*". Esta técnica envolve a atualização de toda a população a cada geração, através dos operadores genéticos permutação e mutação.

b) Algoritmos Genéticos de Estado Estável (*Steady-state Genetic Algorithms*)

Nos algoritmos genéticos de estado estável, também denominados de incrementais (VAVAK; FORGARTY, 1995), apenas alguns cromossomos são atualizados em cada geração, podendo a atualização ser realizada em qualquer instante de tempo. Este comportamento motivou a sua denominação, pois nesta técnica os demais cromossomos da população permanecem estáveis. Assim, ocorre a mistura entre cromossomos novos e da geração anterior, formando a nova população.

Para os algoritmos genéticos seqüenciais até o momento apresentados, cada cromossomo apresenta comprimento fixo. Neste caso, a codificação, bem como a posição de cada gene (*locus)* dentro do cromossomo, apresenta significado unívoco para a solução.

c) Algoritmos Genéticos Desordenados (*Messy Genetic Algorithms*)

Os algoritmos genéticos desordenados foram desenvolvidos por Goldberg em 1989 (WHITLEY et al., 1998). Neste caso, os cromossomos podem apresentar comprimento flexível, e seus genes são ordenados randomicamente, daí a origem do nome destes algoritmos. Nesta representação, cada gene apresenta um par de números inteiros. O primeiro significa o valor, ou significado do gene. O segundo representa a posição deste gene dentro do cromossomo.

Esta categoria de algoritmos genéticos apresenta os mesmos operadores genéticos, ou seja, mutação e permutação. Neste caso, o operador permutação torna-se mais geral, pois o cromossomo pode possuir comprimento variável, e seu valor e posição são codificados internamente ao cromossomo. A aplicação do operador genético mutação também pode atuar nas diferentes posições dentro de cada cromossomo.

4.2.2 Algoritmos Genéticos Paralelos

O conceito envolvido neste caso é a divisão de um problema principal complexo em vários problemas menores, podendo estes apresentarem menor complexidade computacional. Estes problemas menores podem ser traduzidos em programas que podem ser executados em paralelo (simultaneamente), e de forma cooperativa para solucionar o problema principal (CS 267, 1999); (CS 5513, 2000 e (ECE 669, 2000). Cada um destes programas pode ser executado em um processador ou em diferentes processadores em uma máquina multiprocessada. Outra possibilidade é o processamento ocorrer em diferentes máquinas que se comunicam através de uma rede de computadores (GEHRINGER; KENNY, 1999) e (UNDERSTANDING TCP/IP, 1991).

Diversas outras tentativas de resolução do problema principal tem sido testadas, podendo existir algum mecanismo de comunicação e troca de informação, entre os processamentos paralelos, para a resolução do problema (KOTSIS, 1992).

Este tipo de abordagem é muito empregado em processamento paralelo, também denominado de divide-e-conquiste, podendo ser aplicada em diversas modalidades de algoritmos genéticos (WANG, 1997). Algumas destas abordagens utilizam uma única população, enquanto outras dividem a população em diversas subpopulações que podem estar ou não, relativamente isoladas. Algumas abordagens exploram o grande paralelismo proporcionado por arquiteturas massivamente paralelas, com diversos processadores em paralelo (DAMIDIS, 1998) e (HÄNDLER, 2000). Outras podem utilizar sistemas computacionais, com poucos elementos processadores, mas com grande capacidade computacional. A classificação dos algoritmos genéticos paralelos de um modo geral pode ser definida como a seguir (PAZ-95a) e (PAZ-1996):

a) Algoritmos Genéticos de Paralelização Global (*Global Parallelization*)

Também denominado de algoritmos genéticos mestre-escravo, apresenta uma única população, igualmente aos algoritmos genéticos seqüenciais. Nesta técnica a avaliação da função de seleção dos cromossomos mais aptos é distribuída entre os diversos processadores (PAZ, 1996). Os operadores genéticos permutação, mutação e seleção consideram toda a população, daí a origem do nome destes algoritmos. A figura 4.2. apresenta a topologia lógica, na qual a comunicação é realizada entre um processo de software denominado de mestre e diversos escravos.

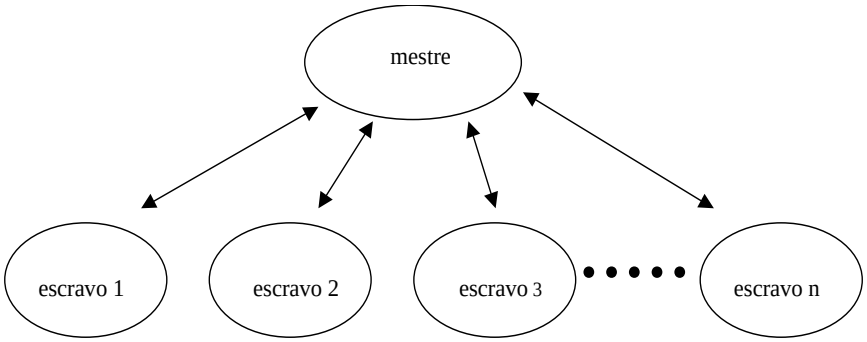

Figura 4.2: Mecanismo de comunicação em algoritmos genéticos mestre-escravo

No esquema de algoritmos genéticos paralelos mestre-escravo, o mestre armazena toda a população, executa os operadores genéticos, e distribui os cromossomos entre os escravos. Os escravos somente avaliam a saúde dos cromossomos. Os algoritmos genéticos de paralelização global podem ser divididos como a seguir:

a.1) Algoritmos Genéticos de Paralelização Global Síncrono

Neste caso, o mestre em sua execução, espera receber o valor referente à saúde de todos os cromossomos calculados pelos seus respectivos escravos. Este cálculo envolve toda população de cromossomos. Devido ao fato do mestre ter que esperar o cálculo da saúde todos os cromossomos da população, pelos seus respectivos escravos, estes algoritmos são denominados de síncrono. Estes algoritmos tem as mesmas propriedades dos algoritmos genéticos seqüenciais, diferenciando somente na velocidade de sua execução (PAZ, 1996).

a.2) Algoritmos Genéticos de Paralelização Global Assíncrono

Nestes algoritmos, ao contrário do anterior, não há parada de execução do mestre, caso a avaliação da saúde de algum escravo esteja sendo feita de forma lenta. Esta avaliação mais lenta pode ser devida, por exemplo, a capacidade de processamento deste escravo ser inferior aos demais escravos do sistema.

Assim, a geração de uma nova população é realizada sem que necessariamente todos os cromossomos tenham sua avaliação de saúde realizada. Desta forma, estes algoritmos são definidos como assíncronos. Devido a esta característica, estes algoritmos apresentam comportamento diferente dos algoritmos genéticos seqüenciais (PAZ, 1996).

b) Algoritmos Genéticos Paralelos de Pequena Granularidade (*Fine Grained Parallel Genetic Algoritms*)

Esta técnica é a mais adequada para ser aplicada em computadores massivamente paralelos (ABU-GHAZALEH; WISLEY, 1996). Neste caso, a população é dividida em pequenos grupos de subpopulações (cromossomos), uma para cada processador disponível (PAZ, 1996), sendo esta a origem do seu nome. Esta arquitetura apresenta uma distribuição espacial bem definida, em função dos processadores existentes. A seleção dos mais aptos é realizada entre as subpopulações vizinhas mais próximas. Pode também haver interação através, da migração de cromossomos entre as subpopulações. A figura 4.3 apresenta a topologia lógica para o esquema de algoritmos genéticos paralelos de pequena granularidade.

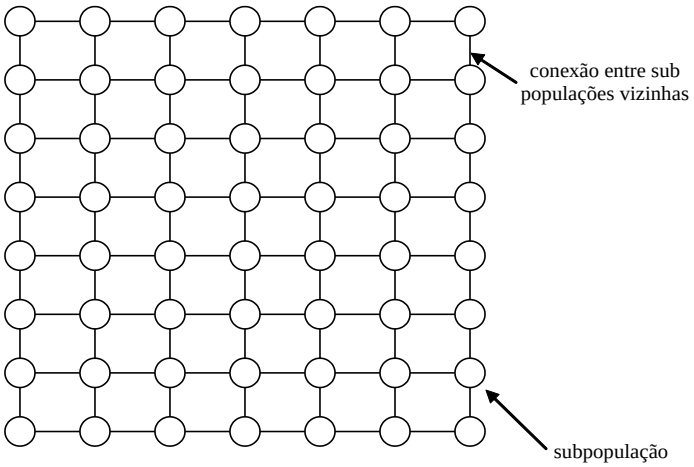

Figura 4.3: Mecanismo de comunicação em alg. gen. paralelos de pequena granularidade

Observe que nesta classe de algoritmos genéticos paralelos, a população apresenta distribuição espacial uniformemente distribuída, sendo que cada subpopulação possui comunicação com as suas subpopulações vizinhas (PAZ, 1996).

c) Algoritmos Genéticos Paralelos de Grande Granularidade (*Coarse Grained Parallel Genetic Algoritms*)

Esta técnica também é conhecida como algoritmos genéticos multi-população (*multi-deme*), apresentando até o momento o maior número de publicações (PAZ, 1996). São algoritmos genéticos com pequeno número de subpopulações, sendo que cada uma delas apresenta tamanho (número de cromossomos) significativamente maior, quando comparado aos algoritmos genéticos paralelos de pequena granularidade.

Nesta categoria de algoritmos genéticos paralelos a troca de cromossomos ocorre ocasionalmente. Esta troca de cromossomos é chamada de migração, sendo controlada por diversos fatores (PAZ, 1996).

Apesar de ser a classe mais popular dos algoritmos genéticos paralelos, é a de mais difícil compreensão, devido principalmente a não existência de um formalismo que represente o efeito da migração dos cromossomos entre as subpopulações, e no desempenho global dos algoritmos (PAZ, 1996). O fato é que as migrações introduzem mudanças fundamentais no comportamento dos algoritmos genéticos, dificultando o seu entendimento e, portanto, a definição de um formalismo matemático, quando comparado aos algoritmos genéticos seqüenciais. Atualmente, encontram-se resultados empíricos na maioria dos artigos publicados, de difícil avaliação, mesmo para a comunidade acadêmica (PAZ, 1996). A figura 4.3 apresenta a topologia lógica para o esquema de algoritmos genéticos paralelos de grande granularidade com múltiplas populações.

A topologia de interconexão ou comunicação entre as diversas subpopulações pode ser bastante variada. Na figura 4.4. está sendo apresentada a topologia em malha na qual a migração pode ser realizada entre quaisquer duas subpopulações.

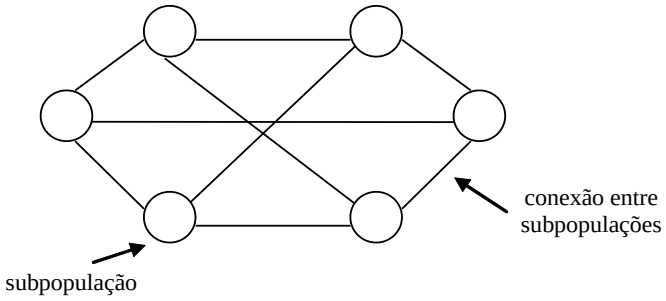

Figura 4.4: Mecanismo de comunicação em alg. gen. paralelos de grande granularidade

c.1) Modelo em Ilhas (*Island Model*)

Nesta subclasse dos algoritmos genéticos paralelos de grande granularidade, considera-se que as populações estão em isolamento geográfico, diminuindo assim o efeito das migrações entre as subpopulações. Tais populações isoladas são conhecidas como "ilhas", semelhante ao fenômeno ocorrida no famoso Arquipélago das ilhas Galápagos, descrito por Charles Darwin, em seu livro *The origin of species* (SHORROCKS, 1978).

As ilhas Galápagos ficaram centenas de anos isoladas do Mundo, produzindo uma variedade vegetal e animal diferente do resto do planeta Terra. Este modelo assume que a migração, quando houver, pode ser realizada de qualquer ilha, para qualquer outra.

c2) Modelo em Ponte (*Stepping Stone Model*)

Esta subclasse diferencia-se do modelo em ilhas pelo fato de que a migração é restrita somente às subpopulações vizinhas. O efeito é como existisse um conjunto de pontes interligando as subpopulações vizinhas. Muitas implementações na prática não diferenciam as classes de modelo em ilhas e em ponte (PAZ, 1995).

A figura 4.5 apresenta a topologia de interconexão entre algoritmos genéticos paralelos em ponte.

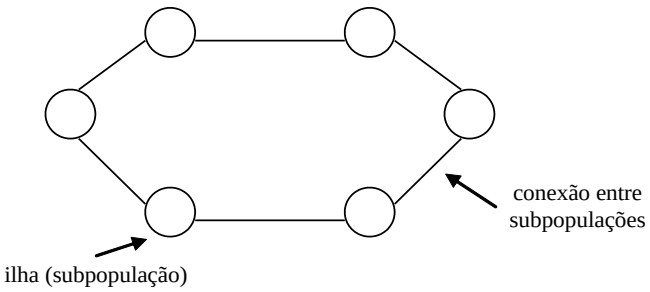

Figura 4.5: Mecanismo de comunicação em algoritmos genéticos paralelos em ponte

d) Algoritmos Genéticos Hierárquicos (*Hierarchicals Genetic Algorithms*)

Esta classe apresenta dois níveis hierárquicos. Cada nível utiliza uma das classes de algoritmos genéticos paralelos apresentados (algoritmos genéticos paralelos mestre-escravo, de pequena granularidade ou grande granularidade). Pode-se inclusive utilizar uma mesma classe para os dois níveis. Na verdade, existem diversas formas de combinar os algoritmos genéticos paralelos, de forma a fornecer diferentes variações de hierarquias. Os três algoritmos genéticos hierárquicos mais populares são apresentadas a seguir (ADAMIDIS, 1994); (PAZ, 1995) e (GORDON; WHTLEY, 1996):

d.1) Algoritmos Genéticos Paralelos Hierárquicos de Pequena e Grande granularidade

Neste caso, o nível superior apresenta a estrutura dos algoritmos genéticos paralelos de grande granularidade, e o nível inferior utiliza os algoritmos genéticos paralelos de pequena granularidade (PAZ, 1995). A figura 4.6 apresenta a estrutura destes algoritmos genéticos paralelos hierárquicos.

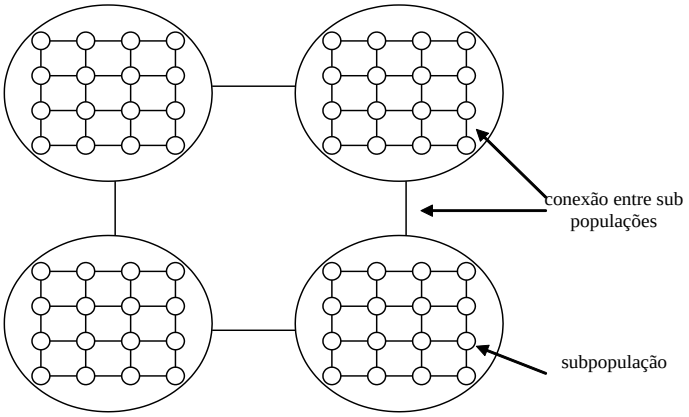

Figura 4.6: Algoritmos genéticos paralelos hierárquicos de pequena e grande granularidade

d.2) Algoritmos Genéticos Paralelos Hierárquicos de grande granularidade e mestre-escravo

Neste caso, o nível superior apresenta a estrutura dos algoritmos genéticos paralelos de grande granularidade, e o nível inferior utiliza os algoritmos genéticos paralelos mestre-escravo. A figura 4.7 apresenta a estrutura destes algoritmos genéticos paralelos hierárquicos.

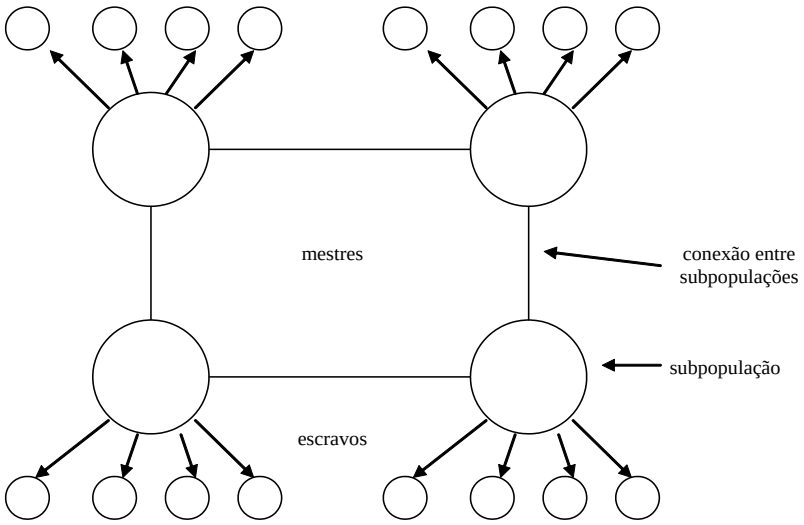

Figura 4.7: Algoritmos genéticos paralelos hierárquicos de grande granularidade e mestre-escravo

Nesta hierarquia, temos que cada subpopulação apresenta um mestre, da classe de algoritmos genéticos mestre-escravo (*master-slave*), e a migração ocorre entre estes mestres.

d.3) Algoritmos Genéticos Paralelos Hierárquicos de Grande Granularidade em ambos os níveis da hierarquia

Esta hierarquia utiliza algoritmos genéticos paralelos de grande granularidade em ambos os níveis, ou seja, são criadas subpopulações em ambos os níveis da hierarquia. A figura 4.8 apresenta a estrutura destes algoritmos genéticos paralelos hierárquicos.

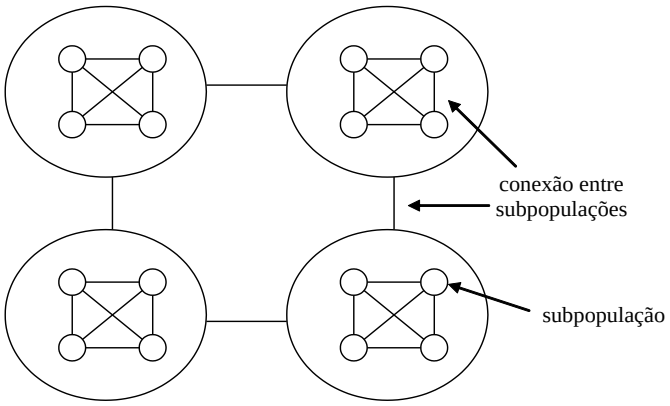

Figura 4.8: Algoritmos genéticos paralelos hierárquicos de grande granularidade em ambos os níveis da hierarquia

Observe que existem subpopulações em ambos os níveis da hierarquia. Na hierarquia inferior normalmente adota-se uma taxa de migração mais elevada. Desta forma, a comunicação entre as subpopulações é mais intensa. O número de conexões entre as subpopulações do nível hierárquico inferior é normalmente superior (PAZ, 1996). Vale notar que as hierarquias mais utilizadas adotam os algoritmos genéticos paralelos de grande granularidade em seu nível superior.

e) Algoritmos Genéticos Híbridos (*Hybrid Genetic Algoritms*)

Nesta classe, os algoritmos genéticos tanto seqüenciais, quanto paralelos, são utilizados de forma complementar com as outras técnicas. Neste caso, técnicas como, redes neurais artificiais, lógica *fuzzy*, podem ser utilizadas na modelagem de um problema, e os algoritmos genéticos podem auxiliar na otimização de algum parâmetro desta modelagem.

Por exemplo, a lógica *fuzzy* é baseada em um conjunto de regras que são armazenados em uma base de conhecimento (banco de dados). Elas podem utilizar os algoritmos genéticos para automatizar o processo de aprendizagem destas regras (CORDÓN; HERRERA, 1997). Da mesma forma, pode-se utilizar algoritmos genéticos para auxiliar na seleção das regras a serem aprendidas, ou então, nos parâmetros que controlam o aprendizado em uma rede neural artificial (SCHAFFER; WHITLEY; ESHELMAN, 1992).

Os algoritmos genéticos paralelos podem trabalhar em conjunto com outros algoritmos de busca com otimização, tais como, encosta ascendente (*hill climbing*), pesquisa tabular (*tabu search*) e têmpera simulada (*simuling anneling*) (CORDÓN; HERRERA, 1997).

4.3 Problemas de Otimização com Restrições

A computação evolutiva, em especial os algoritmos genéticos, tem recebido grande atenção como uma classe de algoritmos para problemas de otimização com restrições. As restrições são proibições que a solução do problema deve respeitar, devido a peculiaridades do problema abordado.

O principal problema da aplicação de algoritmos genéticos em problemas de otimização com restrição, está no fato em como manipular tais restrições. Os operadores genéticos,

tais como a permutação e mutação, podem gerar soluções (cromossomos) inválidas (GEN; CHENG, 1996). Existem diversas estratégias para a manipulação de restrições que podem ser aplicadas em algoritmos genéticos (MICHALEWICZ; REYNOLDS; FOGEL, 1995):

- Rejeição: Todas as soluções inválidas são descartadas durante o processo de evolução dos algoritmos genéticos.
- Reparação: Utiliza-se de um processo, ou função de reparação, que converte uma solução inválida, gerada pelo processo de evolução, em uma solução válida.
- Operadores genéticos modificados: Os operadores genéticos são modificados de forma a se tornarem especializados na representação e manutenção de soluções válidas. Estes operadores modificados devem ser especializados, específicos para o tipo de problema abordado.
- Penalidades: Transforma soluções inválidas em soluções válidas, através da penalidade de soluções inválidas.

Cada uma destas estratégias apresenta vantagens e desvantagens. Em diversos problemas práticos, que utilizam algoritmos genéticos como técnica de otimização, observa-se que a população pode ser composta, em sua maioria, por soluções inválidas. Neste caso, a utilização de técnicas de otimização que permitam movimentar-se de regiões do espaço de soluções inviáveis, para soluções viáveis, normalmente apresenta maior rapidez de otimização, bem como melhores soluções finais. Esta é uma característica da utilização de penalidades que motiva a sua utilização em conjunto com algoritmos genéticos (GEN; CHENG, 1996).

Normalmente, o espaço de soluções para estes problemas apresenta duas áreas bem definidas. A primeira região, das soluções viáveis, e a segunda região, das soluções inviáveis. A figura 4.9 apresenta a representação do espaço de pesquisa, e as regiões de soluções viáveis e inviáveis.

O principal objetivo da estratégia de otimização por penalidades está em definir a função de penalidade denominada por $p_{(x)}$. A função de penalidade em conjunto com a função de aptidão, denominada por $f_{(x)}$, orienta os algoritmos genéticos de regiões de soluções inviáveis para viáveis, que estão em busca da solução ótima. A função de aptidão é o

elemento básico dos algoritmos genéticos, pois ele mede o grau de aptidão de cada solução (cromossomo) a cada geração dos algoritmos genéticos em relação ao problema abordado. A função de aptidão orienta o processo evolutivo em direção ao melhor cromossomo, ou seja, em busca da melhor solução para o problema em analise (FREGNI, 1997).

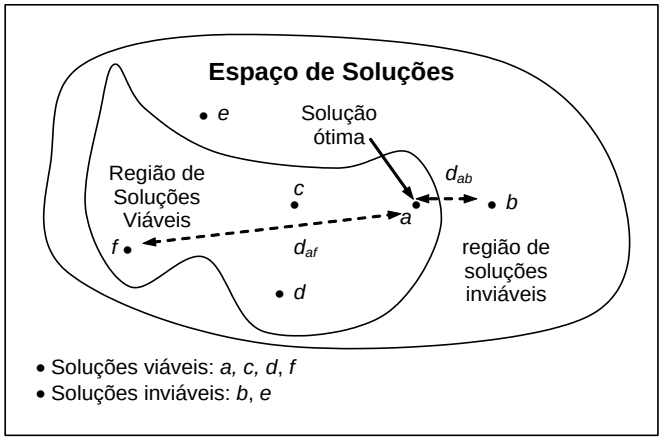

Figura 4.9: Espaço de solução: áreas de soluções viáveis e enviáveis

Em geral existem duas formas possíveis de se construir uma função de avaliação $eval_{(x)}$, que relaciona a função de aptidão e a função de penalidades (GEN; CHENG, 1996):

- **Avaliação por adição**

Sendo $eval_{(x)} = f_{(x)}+p_{(x)}$, no qual x representa uma solução. Em problemas de maximização requer que:

$$\begin{cases} p_{(x)} = 0, \text{ se x é viável} \\ p_{(x)} < 0, \text{ caso contrário} \end{cases}$$

- **Avaliação por multiplicação**

Sendo $eval_{(x)} = f_{(x)} \cdot p_{(x)}$, no qual x também representa uma solução. Em problemas de maximização requer que:

$$\begin{cases} p_{(x)} = 1, \text{ se x é viável} \\ p_{(x)} < 1, \text{ caso contrário} \end{cases}$$

Existem duas premissas que podem auxiliar na criação de funções de penalidades, com o objetivo de orientar os algoritmos genéticos de forma a realizar otimizações mais eficientes (RICHARDSON et al., 1989):

- Funções de penalidades são funções dependentes da distância em relação a soluções viáveis. O termo distância pode ser considerado, por exemplo, como a distância euclidiana (geométrica), ou então, a de *hamming* (número de *bits* distintos). Por exemplo, na figura 4.9 a solução inviável *b* está bem mais próxima da solução ótima *a* do que a solução viável *f*.
- Em problemas com poucas restrições a penalidade é função unicamente do número de violações de restrições.

As funções de penalidade podem ainda ser classificadas em outras duas classes (GEN; CHENG, 1996):

- **Penalidade constate**

Atribui um valor constante à penalidade, independente do quão distante a função de aptidão esteja de uma solução viável. Normalmente, esta solução é menos eficiente em problemas de alta complexidade (COELHO, 1998).

- **Penalidade variável**

Atribui um valor variável à penalidade, dependente de quão distante a função de aptidão está de uma solução viável. Em geral, a penalidade variável contém dois componentes:

  - Taxa de penalidade variável: Pode ser ajustada de acordo com o grau de violação da restrição, aumentando a pressão da penalidade conforme a distância ou grau de violação da restrição aumente.
  - Número de interações dos algoritmos genéticos: A pressão da penalidade é incrementada com o processo de evolução, ou seja, o número de interações dos algoritmos genéticos.

4.4 Diversidade Genética

A diversidade genética, ou também denominada de diversidade populacional, é um dos fatores que interferem na velocidade de convergência. Ela mede o grau de diferenças de genótipo entre os diversos indivíduos de uma população, ou seja, dos genes dentro do cromossomo destes indivíduos. Assim, uma elevada diversidade genética reflete que existe uma grande quantidade de alelos, ou seja, de diferentes genes presentes na população. A diversidade genética informa o grau de espalhamento da população sobre o

espaço de busca. Uma possível métrica para a Diversidade Genética *DG* pode ser dada por (BANZHAF; REEVES, 1999):

$$DG = \frac{AP}{AT} \text{ (equação 1)}$$

onde:

AP = quantidade de alelos existentes na população.

AT = quantidade de alelos teoricamente possíveis, ou seja, quantidade total de diferentes genes para a população.

Outras formas de medida da diferença entre os indivíduos de uma população podem ser através, por exemplo, da distância de *hamming* entre os genes, ou então, das distâncias euclidianas dos fenótipos, também chamada de distância fenotipal (HOLLAND, 2000).

A diversidade genética está relacionada à variabilidade genética dos indivíduos da população sendo que, quanto maior a diversidade genética, maior a diferença entre os indivíduos, e maior o espalhamento das possíveis soluções na população em relação ao espaço de busca. Este espalhamento pode ser máximo no início do processo, quando a população inicial é gerada aleatoriamente, tornando-se menor com o avanço do processo evolutivo (BODENHOFER, 2004). Assim, a diversidade genética favorece a exploração por soluções de melhor qualidade.

Uma forma de aumentar-se a diversidade genética é através do aumento da taxa de mutação. Este aumento da taxa de mutação faz com que aumente a taxa com que novos bits sejam gerados aleatoriamente. Este fato provoca um afastamento entre os bits, na proporção em que é aumentada a taxa de mutação. Uma segunda forma de aumentar-se a diversidade genética é através do aumento do tamanho da população.

4.5 Pressão Seletiva

Também denominada de intensidade seletiva, é outro fator que interfere na velocidade de convergência. A pressão seletiva está relacionada à velocidade e ao método de seleção utilizado. Ela marca o progresso, de geração a geração, do processo de evolução do grau de aptidão média dos indivíduos selecionados em comparação aos indivíduos da população. A pressão seletiva regula o grau de privilégio de alguns indivíduos durante o

processo de seleção, em detrimento de outros indivíduos menos aptos. A definição de intensidade seletiva (I) , ou pressão seletiva, é dada pela variação na aptidão média da população que é induzida pelo método de seleção. A expressão é dada por (PACHECO, 1998):

$$I = \frac{f^* - f}{\sigma} \quad \text{(equação 2)}$$

Na qual f é a aptidão média da população, f^* é o valor esperado da aptidão após o processo de seleção, e σ é o desvio padrão dos valores de aptidão da população anterior ao processo de seleção. A equação 2 é genérica, sendo diretamente dependente do processo de seleção utilizado.

Se a probabilidade de seleção de alguns indivíduos difere muito em relação aos demais indivíduos da população, pode-se afirmar que a pressão seletiva será grande. Agora, quando as probabilidades de seleção são próximas, pode-se afirmar que a pressão seletiva é baixa. Quando a pressão seletiva é nula, o processo de busca é praticamente uma busca aleatória, uma vez que todos os indivíduos têm a mesma probabilidade de serem selecionados e, portanto, de sobreviverem.

A pressão seletiva acelera o processo de convergência, sendo positivo se ocorrer no sentido de encontrar um máximo global, poupando tempo de processamento. Agora, se conduzir a um máximo local não desejado, será prejudicial, negativo, provocando uma convergência prematura, dificultando a busca do ótimo global.

4.6 Funções Multimodais

Funções multimodais são aquelas que apresentam diversas inflexões, gerando diversos pontos de mínimos ou máximos locais (CORTES; SAAVEDRA; PEREIRA, 2001) e (OLIVEIRA, 2001). A figura 4.10 apresenta um esboço de uma função multimodal, contendo diversos máximos locais, e um correspondente máximo global. Este máximo global é o ponto de máximo procurado pelo algoritmo de otimização.

A maioria dos algoritmos evolutivos, entre eles os algoritmos genéticos, não são projetados para encontrar vários pontos de máximo simultaneamente, convergindo para o maior ponto de máximo entre eles (OLIVEIRA, 2001). Este fato faz com que estes

algoritmos apresentem o problema de convergência prematura apresentado. Os métodos utilizados para ajudar a resolver este tipo de problema são denominados de nichos (*niching methods*) (FREGNI, 1997); (MAHFOUD, 1995) e (OLIVEIRA, 2001). Estes métodos procuram estender os algoritmos genéticos para domínios que requerem a localização e a manutenção de soluções múltiplas, impedindo a concentração da população em um único ponto.

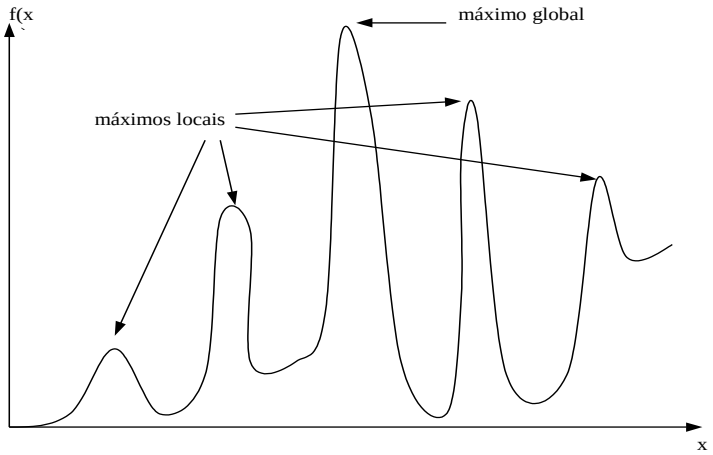

Figura 4.10: Exemplo de função multimodal

A técnica denominada de aglomeração (*crowding*) (OLIVEIRA, 2001), na qual utiliza-se o conceito de similaridade entre indivíduos, elimina os indivíduos semelhantes da população, mantendo apenas o indivíduo similar mais promissor, ou seja, de maior aptidão. Desta forma, a distribuição dos indivíduos da população inicial é preservada, apresentando uma migração mais lenta para os máximos locais, que estejam próximos deste indivíduo (FREGNI, 1997). Proposta semelhante, denominada de algoritmos genéticos *struggle* (GRÜNINGER; WALLACE, 1996), elimina da população os indivíduos semelhantes com menor aptidão. A medida da similaridade entre indivíduos pode ser determinada através da distância euclidiana, ou através da própria distância de *hamming*. Note que o conceito de nicho acaba sendo apresentado implicitamente. Durante experimentos (GRÜNINGER; WALLACE, 1996) observou que são formados nichos em torno dos indivíduos mais aptos da população inicial. Desta forma, o espalhamento populacional desde seu início torna-se fundamental, determinando o número de regiões e nichos a serem explorados. Outro fato interessante é que, em

estágios mais avançados de evolução, a similaridade entre indivíduos aumenta, fazendo com que alguns nichos sejam englobados por outros. Neste caso, o processo de mutação torna-se uma ferramenta fundamental para a criação de novos nichos.

Outro método para estender os algoritmos genéticos é denominado de aptidão compartilhada (*sharing fitness*) (GOLDBERG; RICHARDSON, 1987]) e consiste na redução da aptidão de um indivíduo proporcionalmente ao número de indivíduos pertencentes ao mesmo nicho. O objetivo é estimular a sobrevivência e exploração de indivíduos que estejam isolados. Desta forma, consegue-se uma maior exploração do espaço de pesquisa. A aptidão compartilhada afeta o mecanismo de seleção. Uma forma de contabilizar a aptidão compartilhada do i-ésimo indivíduo é dada por (OLIVEIRA, 2001):

$$fc_i = \frac{f_i}{m_i} \quad \text{(equação 3)}$$

No qual fc_i é a aptidão compartilhada, f_i é a aptidão original do indivíduo e m_i é o número de indivíduos no mesmo nicho. Em todos os métodos de nicho apresentados adota-se o conceito de recursos, através do qual estabelecem-se limites para a quantidade de indivíduos por nicho, ou seja, cada nicho pode comportar um número máximo de indivíduos, diretamente proporcional a sua “fertilidade”. Esta fertilidade é medida em função da aptidão em um determinado ponto de máximo, quando comparado a outros pontos de máximos do espaço amostral (OLIVEIRA, 2001).

No próximo capítulo é apresentado a proposta de um modelo de otimização de demanda em infra-estrutura aeronáutica utilizando alguns conceitos de algoritmos genéticos.

Este capítulo apresenta uma proposta de Modelo de Otimização de Demanda (MOD) em infra-estrutura aeronáutica. Adicionalmente são apresentados alguns conceitos de algoritmos genéticos que fazem parte do modelo proposto de otimização.

5 PROPOSTA DE UM MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA

> *"O objetivo primordial e preocupação máxima das autoridades aeronáuticas de todos os países e, em conseqüência, também da Organização da Aviação Civil (OACI), é aumentar, cada vez mais, a capacidade do espaço aéreo, acomodando um número crescente de aeronaves em uma determinada área ou rota, simultaneamente, com níveis idênticos ou superiores de segurança das operações aéreas atuais"*

Implantação e Transição na América do Sul,
Brigadeiro do Ar Washington Carlos de Campos Machado, Revista Aeroespaço, 2000

Este capítulo apresenta, em detalhes, a principal contribuição deste trabalho de pesquisa. Esta contribuição refere-se à proposta de um modelo de otimização de demanda (MOD) em infra-estrutura aeronáutica.

O modelo proposto de otimização refere-se a um sistema computacional que visa otimizar a programação da escala global, dentro do contexto de gerenciamento de tráfego aéreo (ATM – *Air Traffic Managment*), considerando a previsão de demanda de planos de vôos repetitivos (RPL - *Repetitive Flight Plans*) e as capacidades nominais declaradas dos setores de uma dada infra-estrutura aeronáutica.

A previsão de demanda das companhias aéreas é obtida através das intenções de vôo, fornecidas por elas. A partir desta previsão de demanda, é criado um diagrama de análise de situação para cada um dos setores e aeroportos da infra-estrutura aérea. A figura 5.1 apresenta o diagrama de análise de situação para um setor de área de controle terminal de São Paulo. Este diagrama de análise de situação foi fornecido pelo Centro de

Gerenciamento da Navegação Aérea (CGNA), localizado em São José dos Campos - SP, através de seu sistema de análise de situação de vôo, denominado do SAS – AuATFM – FMP (*Air Traffic Flow Management - Flow Management Point*).

Este diagrama apresenta no eixo vertical a previsão de ocupação do setor ou aeroporto em cada instante de tempo. Adicionalmente, são apresentadas as linhas de congestionamento e saturação. Considera-se um setor como congestionado, quando a sua ocupação apresenta 80% ou mais de sua capacidade nominal declarada. Considera-se como saturado quando a demanda ultrapassar a capacidade nominal declarada do setor.

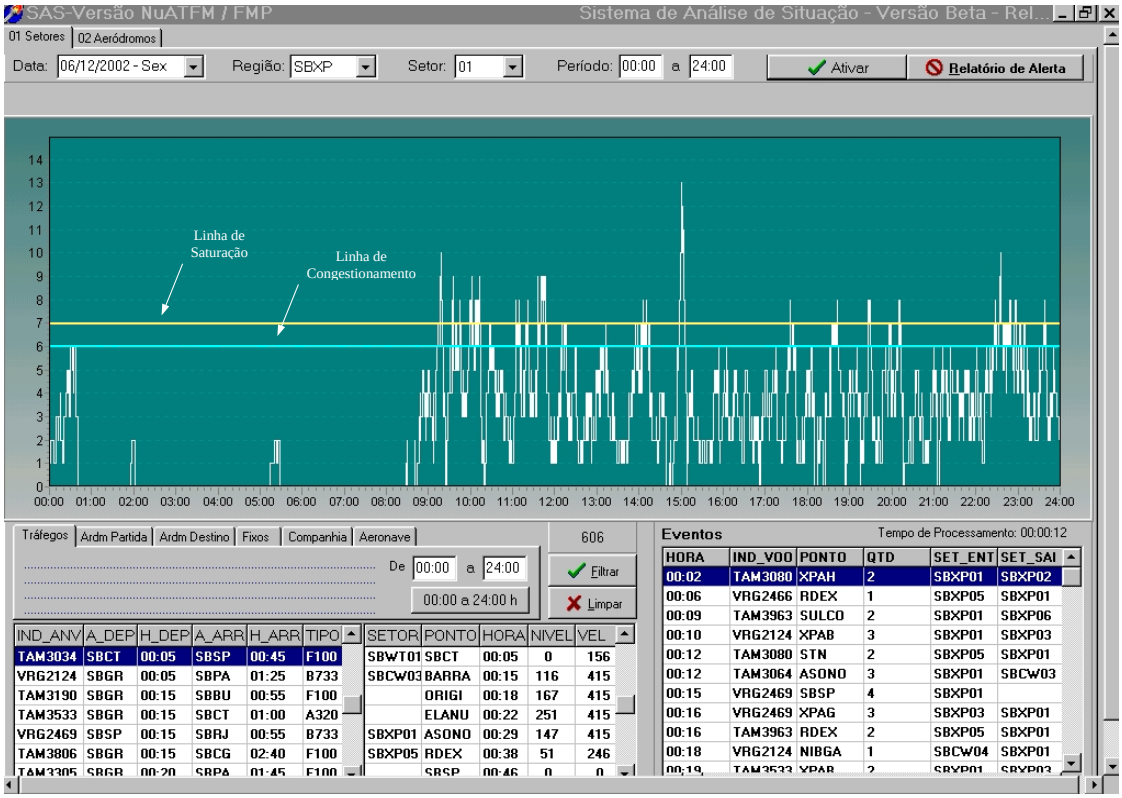

Figura 5.1: Diag. de análise de situação em uma área de controle terminal de São Paulo

No eixo horizontal é apresentado o período de tempo no qual é realizada a análise de situação do setor. Informações adicionais como, tipo de aeronave, horário de entrada no setor, identificação do setor ocupado, entre outras, são apresentadas de forma a fornecer maiores detalhes, permitindo assim, uma análise mais aprofundada da situação do setor da infra-estrutura aérea.

Como pode ser observado, em diversos pontos do diagrama, a demanda ultrapassa as linhas de congestionamento e saturação. Em uma situação real, quando a linha de congestionamento é ultrapassada, a ocupação do setor, ainda que permitida, pode ser realizada com certas restrições, procurando-se manter o nível de segurança. Neste caso, pode ser necessária alguma ação pelo controlador de tráfego aéreo, visando manter a segurança em níveis aceitáveis. Quando a situação de saturação ocorre, obrigatoriamente será realizada alguma ação de forma a equilibrar a situação e tornar a demanda inferior à capacidade nominal declarada do setor.

Na realidade, o limite máximo para a capacidade nominal declarada do setor não é tão preciso. Por exemplo, um modelo de simulação computacional denominado de DORASTAK, desenvolvido pela autoridade de aviação civil inglesa (CAA - *Civil Aviation Authority*), adota que o limite máximo de ocupação para um setor seja igual a 120% da sua capacidade nominal declarada (SIEWERDT, 2003a). Este limite superior é aqui identificado e denominado como uma situação de saturação aceitável. Neste trabalho de pesquisa ele é considerado o limite máximo que a demanda pode atingir em cada setor, de forma a obter-se igualmente uma carga de trabalho de gerenciamento máxima e aceitável, em cada um dos setores da infra-estrutura aeronáutica. O diagrama de análise de situação seria um primeiro levantamento da situação futura em um período de tempo determinado, escolhido com antecedência.

Na prática, esta situação futura poderá ter alterações, dependendo da análise deste diagrama de análise de situação, pelos órgãos de gerenciamento de tráfego aéreo. Nesta análise, o órgão de gerenciamento de tráfego aéreo tem a previsão dos locais e horários em que haverá congestionamentos, saturações aceitáveis e supersaturações (demanda superior a 120% da capacidade nominal declarada do setor). Assim, podem-se antecipar problemas futuros e programar ações a serem realizadas durante a implantação dos vôos. O grande problema atual é que estas ações de correção são realizadas pontualmente, sem considerar o seu efeito sobre as demais regiões, ou seja, sobre toda a infra-estrutura aeronáutica.

Na realidade, essas ações pontuais têm como objetivo a acomodação do tráfego aéreo projetado em um espaço físico delimitado, que pode compreender no máximo alguns aeroportos e setores, que apresentam congestionamento excessivo[1].

Esta medida de intervenção pontual acaba não sendo ideal, resolvendo apenas pontualmente o problema de congestionamento podendo, em alguns casos, criar maiores transtornos para o contexto geral dos serviços de transporte aéreo, através dos efeitos cascata e avalanche. Neste caso, considerado como situação extrema, mesmo ações restritivas, conforme já apresentado no capítulo 2, podem também se tornar insuficientes.

A presente proposta de otimização vem atuar exatamente neste aspecto, ou seja, procurar produzir uma otimização de tráfego que englobe diversas partes, ou até mesmo, toda a infra-estrutura aeronáutica, acomodando de forma mais eficiente a demanda de tráfego aéreo projetada para um período futuro e aumentando, desta forma, os níveis de segurança atualmente praticados. Desta forma, gera-se uma menor carga de trabalho (*Workload*) de gerenciamento e estresse aos controladores de tráfego aéreo, permitindo maior qualidade e segurança dos serviços prestados por estes profissionais. Neste trabalho de pesquisa é considerada a demanda de tráfego em setores de área de controle terminal e do espaço aéreo superior da infra-esturura aeronáutica, fornecidos pelo Centro de Gerenciamento da Navegação Aérea[1].

Outra questão atual, e que poderá-se agravar no futuro, é que o desbalanceamento entre demanda e capacidade nominal declarada deverá ser ainda maior, podendo as ações, hoje realizadas serem insuficientes. Fato agravante é que as ações de correção na situação atual são ajustadas por operadores humanos, que podem resultar em atrasos dos vôos de forma progressiva. Estes atrasos podem ser tanto em solo, quanto em vôo. Em solo, acarretam descontentamento dos passageiros, menor número de vôos disponibilizados pelas companhias aéreas, ocupação excessiva (além da programada) em solo dos aeroportos pelas aeronaves, etc. Em vôo, geram igualmente o descontentamento dos passageiros, pois os vôos acabam durando maior tempo que o estimado, gerando

[1] Centro Tecnológico da Aeronáutica, Centro de Gerenciamento e Navegação Aérea, **Reunião de estudo**, São José dos Campos, em 15 março de 2003. Comunicação Verbal através de especialistas em tráfego aéreo.

consumo excessivo de combustível pelas aeronaves. Além destes, podem ser citados os fenômenos meteorológicos que também geram atrasos, tanto na decolagem, como na aterrisagem das aeronaves, muito comuns em regiões com condições climáticas instáveis.

Todos os problemas apresentados, de forma direta ou indireta, trazem também prejuízos financeiros, seja para as companhias aéreas, sejam aos seus passageiros.

Igualmente, as companhias aéreas desejam manter seus vôos em horários comerciais que são atrativos financeiramente. Este fato acaba acarretando em grande competição entre as diversas companhias aéreas, por horários dos vôos, pois os mesmos não podem ser disponibilizados a todas as companhias simultaneamente. Um dos fatores limitantes é o limite de capacidade da infra-estrutura aeronáutica, bem como de seu gerenciamento, de forma a fornecer serviços de transporte aéreo de qualidade e seguro.

Em resumo, é desejável que se consiga um perfil do diagrama de análise de situação que esteja o mais próximo possível do desejado pelas companhias aéreas e que possa ser realizável no dia de sua operação. Igualmente se deseja que em todos os setores da infra-estrutura aeronáutica a demanda esteja abaixo da situação de supersaturação.

Tendo como referência o ambiente descrito, é fundamental o desenvolvimento de ferramentas computacionais de apoio à decisão e principalmente de planejamento, que permitam obter, através de um processo de otimização, um conjunto de perfis de demanda que sejam mais próximos possíveis do perfil de demanda desejável pelas empresas aéreas, sem atingir a situação de supersaturação nos setores da infra-estrutura aérea. Caso não se consiga atingir tais objetivos é fundamental a flexibilização de alguns parâmetros, como os atrasos em setores e aeroportos, de forma a permitir que a supersaturação não seja atingida.

Um dos objetivos do processo de otimização é eliminar “gargalos”, principalmente os encontrados em áreas próximas aos aeroportos que apresentam grandes congestionamentos (SIEWERDT, 2002).

Após o processo de otimização podem existir vários perfis de demanda, um para cada setor da infra-estrutura aeronáutica. A otimização deve ser realizada simultaneamente sobre uma área selecionada da infra-estrutura aeronáutica. A principal característica dos

perfis otimizados será a diminuição dos “picos de demanda” encontrados atualmente. Supondo que existam mais de uma opção para os perfis de demanda, é importante fornecer informações adicionais sobre o impacto destes perfis na infra-estrutura aeronáutica e sobre os serviços oferecidos pelo sistema de transporte aéreo permitindo, desta forma, a opção pelo mais adequado e seguro.

A grande dificuldade encontrada neste tipo de problema é que os diversos setores da infra-estrutura aérea apresentam diagramas de análise de situação individuais, que descrevem a ocupação destes ao longo do tempo. Todos estes setores são interconectados através de diversas rotas, que cruzam vários setores seqüencialmente. Uma alteração de ocupação em um de seus setores, por menor que seja, mesmo por uma aeronave, pode gerar atrasos, que são refletidos em outros setores da infra-estrutura aeronáutica.

O presente trabalho de pesquisa propõe um modelo de otimização de demanda (MOD) que visa alcançar os objetivos apresentados. A seguir é apresentado o modelo de otimização desenvolvido.

5.1 Modelo de Otimização Genérico

Para o desenvolvimento deste modelo tem como premissa a existência de uma infra-estrutura aérea genérica hipotética, apresentada na figura 5.2.

O setor é uma porção do espaço aéreo, controlado por um controlador de tráfego aéreo. O objetivo do controlador de tráfego aéreo é garantir que, durante o período de tempo em que as aeronaves estejam dentro do setor, por ele gerenciado, possam realizar os seus vôos com segurança (*safety*). Desta forma, as aeronaves devem passar pelo setor, por ele gerenciado, com o menor risco de colisão possível sendo repassadas de forma segura a outro órgão de controle de tráfego aéreo, seja ele um Controle de Aproximação (APP - *Approach Control*), um Centro de Controle de Área (ACC - *Area Control Center*), ou mesmo uma torre de controle (TWR - *Tower control*).

No modelo de otimização proposto utiliza-se o conceito de capacidade nominal declarada, que se refere ao número máximo de aeronaves que cada setor ou aeroporto pode suportar, dentro de níveis aceitáveis de segurança. Aqui é assumido que a

capacidade nominal declarada apresenta um valor fixo, determinado e fornecido antecipadamente.

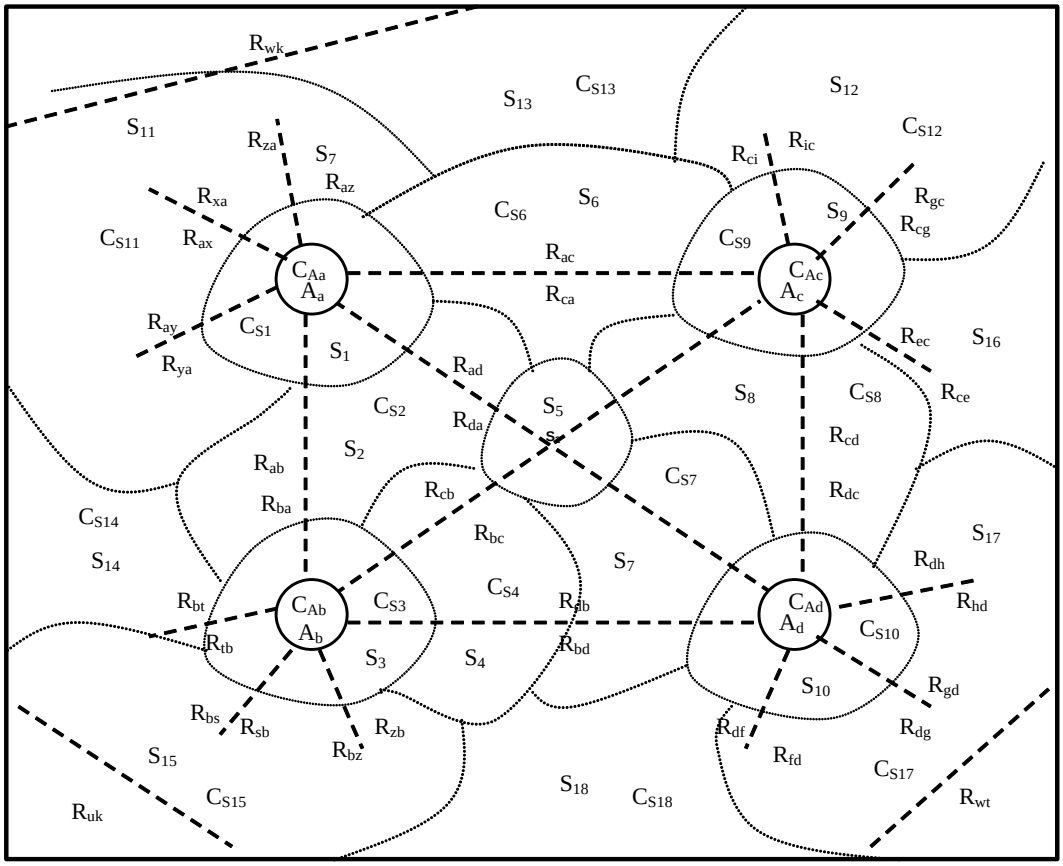

Figura 5.2: Infra-estrutura aérea hipotética

Sendo:

A_n: aeroporto n,

R_{xy}: rota que interliga os aeroportos x e y,

S_t: setor t, e

C_i: capacidade nominal declarada do setor ou aeroporto i.

Outro conceito importante é o de rota, aqui considerado como uma seqüência de setores do espaço aéreo, sejam eles de área de controle terminal ou espaço aéreo superior, desde um aeroporto origem e até um aeroporto destino, que cada aeronave deve ocupar. Basicamente as rotas podem ser classificadas em:

- **Rotas diretas**

Uma rota é considerada direta, ou ponto-a-ponto, quando interliga um aeroporto origem a outro aeroporto destino. Exemplos de rotas diretas na infra-estrutura aérea da figura 5.2. podem ser:

R_{bc}= (A_b, S_3, S_4, S_5, S_8, S_9 e A_c), ou então,

R_{ad}= (A_a, S_1, S_2, S_5, S_7, S_{10} e A_d) entre outras.

- **Rotas indiretas**

Uma rota é considerada indireta quando utiliza um aeroporto intermediário para interligar os aeroportos origem e destino. São também identificadas como rotas com escala. Exemplos de rotas indiretas são:

R_{acd}= (A_a, S_1, S_6, S_9, A_c, S_9, S_8, S_{10} e A_d),

R_{dca}= (A_d, S_{10}, S_8, S_9, A_c, S_9, S_6, S_1 e A_a) entre outras.

O modelo proposto de otimização de demanda (MOD) cria um conceito denominado de cenário aeronáutico, composto por uma infra-estrutura aeronáutica e uma demanda de tráfego aéreo a ele submetida. Para este cenário aeronáutico apresentar maior realismo é considerado as demais rotas e suas respectivas demandas externas, que se intercomunicam com as rotas de dentro do cenário aeronáutico. Ou seja, a infra-estrutura externa e sua correspondente demanda, que englobam ou interfaceiam com cenário aeronáutico analisado, são considerados como um único setor que fornece e recebe aeronaves para o cenário aeronáutico estudado. Em função desta conceituação as rotas diretas e indiretas podem ser subdivididas em uma das 4 categorias a seguir.

- **Rotas internas**

São rotas com origem e destino dentro do cenário aeronáutico analisado como, por exemplo:

R_{ab}= (A_a, S_1, S_2, S_3 e A_b),

R_{ba}= (A_b, S_3, S_2, S_1 e A_a),

R_{ac}= (A_a, S_1, S_6, S_9 e A_c),

R_{ca}= (A_c, S_9, S_6, S_1 e A_a), entre outras.

- **Rotas internas-externas**

São rotas com origem dentro e destino fora do cenário aeronáutico analisado como, por exemplo:

R_{a*}= (A_a, S_1, S_{11}),

R_{d*}= (A_d, S_{10}, S_7, S_5 , S_6, S_{13}) entre outros

* : aeroporto destino fora do cenário aeronáutico analisado.

- **Rotas externas-internas**

São rotas com origem fora e destino dentro do cenário aeronáutico analisado como, por exemplo:

R_{*b}= (S_{15}, S_3, A_b),

R_{*b}= (S_{16}, S_8, S_7 , S_4, S_3, A_b) entre outros.

* : aeroporto origem fora do cenário aeronáutico analisado.

- **Rotas externas-externas**

São rotas com origem e destino fora do cenário aeronáutico analisado como, por exemplo:

R_{**}= (S_{11}),

R_{**}= (S_{14}, S_2, S_5 , S_8, S_{16}) entre outros.

* : aeroporto destino/destino fora do cenário aeronáutico analisado.

5.1.1 Diagramas de Ocupação

Neste item é desenvolvido o conceito de diagrama de ocupação. Para tal, será considerado um cenário aeronáutico composto por 5 aeronaves denominadas por (AE_i) ocupando os aeroportos e setores aeronáuticos A_a, S_1, S_6, S_9 e A_c, conforme a figura 5.3.

Para o cenário aeronáutico apresentado na figura 5.3, supor os tempos de ocupação das aeronaves em cada setor e aeroporto conforme apresentado na tabela 5.1.

Considere AE_n uma aeronave n, t_e o horário de entrada da aeronave no setor ou aeroporto em hh:mm (hora:minuto) e t_s o tempo de saída da aeronave do setor ou aeroporto em hh:mm.

O cenário aeronáutico apresentado na figura 5.3 e tabela 5.1 compreende o intervalo de tempo entre 11hs 05 min, e 12 hs 28hs de um determinado dia. Este cenário aeronáutico,

em um caso prático, poderá compreender períodos correspondentes a um dia, uma semana ou mesmo um ou mais meses inteiros.

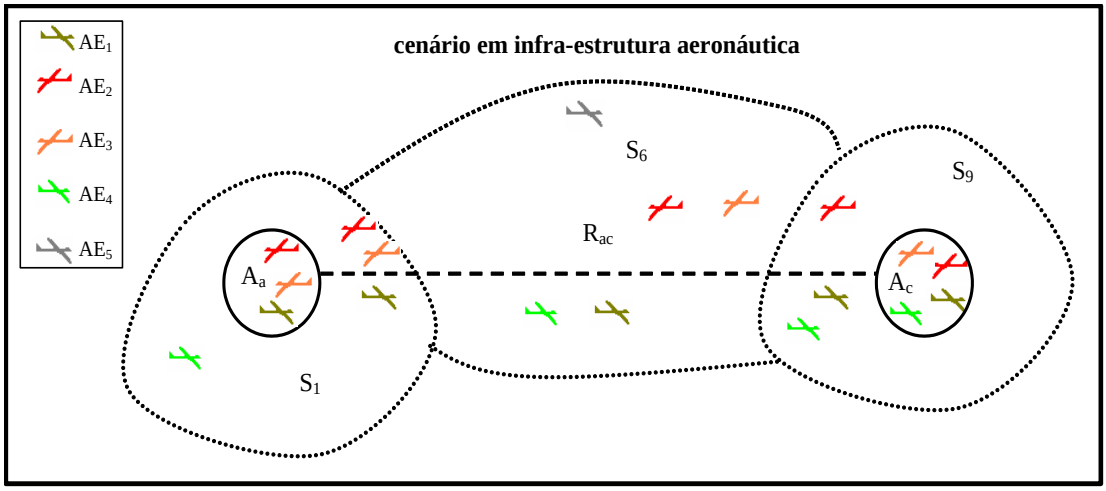

Figura 5.3: Ocupação dos setores e aeroportos A_a, S_6, S_9 e A_c

	A_a		S_1		S_6		S_9		A_c	
Aeronave	t_e	t_s	t_e	t_s	t_e	t_s	t_e	t_s	t_f	t_s
AE_1	11:05	11:20	11:20	11:30	11:30	11:55	11:55	12:05	12:05	12:10
AE_2	11:15	11:30	11:30	11:45	11:45	12:05	12:05	12:15	12:15	12:28
AE_3	11:25	11:35	11:35	11:45	11:45	12:00	12:00	12:10	12:10	12:20
AE_4	-	-	11:40	11:50	11:50	12:10	12:10	12:20	12:20	12:24
AE_5	-	-	-	-	11:35	11:55	-	-	-	-

Tabela 5.1: Tempos de ocupação de cada setor e aeroporto

Para representar a ocupação das aeronaves AE_n em cada setor ou aeroporto, durante o período de tempo em análise, criou-se o conceito de diagrama de ocupação. Um diagrama de ocupação representa a ocupação de todas as aeronaves que ocupam um determinado setor ou aeroporto, durante o período de tempo completo em análise. A figura 5.4 apresenta o diagrama de ocupação para o aeroporto A_a.

O eixo horizontal do diagrama de ocupação representa o tempo de ocupação do aeroporto A_a pelas aeronaves AE_n, e o eixo vertical representa o número de aeronaves AE_n que ocupam o aeroporto A_a.

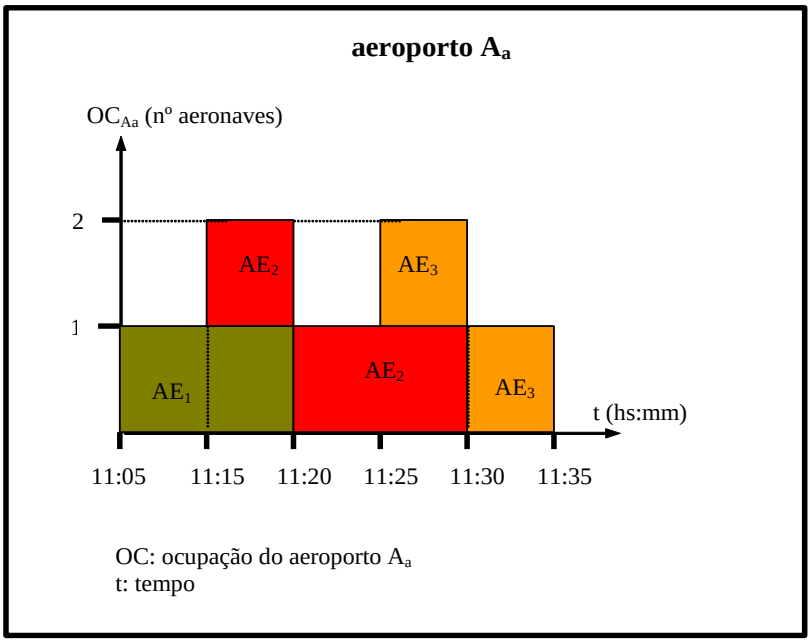

Figura 5.4: Diagrama de ocupação para o Aeroporto A_a

O diagrama de ocupação é um artifício criado para representar a demanda em cada setor ou aeroporto da infra-estrutura aeronáutica. A partir do exposto, os diagramas de ocupação para os aeroportos e setores A_a, S_1, S_6, S_9 e A_c são apresentados na figura 5.5.

Cada diagrama de ocupação pode apresentar uma quantidade máxima AE_n de aeronaves simultâneas, sendo a quantidade limitada pela capacidade de cada setor ou aeroporto da infra-estrutura aeronáutico. Cada aeronave AE_n pode apresentar um tempo diferente de ocupação em um mesmo setor, como pode ser observado na figura 5.5. Este fato pode ser devido a diversos fatores como, por exemplo, diferentes velocidades. O mesmo pode ocorrer nos aeroportos, devido a diferentes logística internas, quantidade de aeronaves existentes, diferentes programações de decolagem etc.

Normalmente, um mesmo tipo de aeronave apresenta o mesmo tempo de permanência em um setor, devido apresentar velocidade igual e constante durante o vôo no espaço aéreo superior. Esta velocidade é denominada de velocidade de cruzeiro, em que o consumo de combustível e as condições de viagem são ideais. Em certas circunstâncias especiais, tais como, em excesso de congestionamento em áreas de controle terminal (TMA), condições meteorológicas adversas, intervenção dos controladores de tráfego

aéreo, entre outras, o tempo de permanência das aeronaves nos setores e aeroportos pode apresentar uma certa variação.

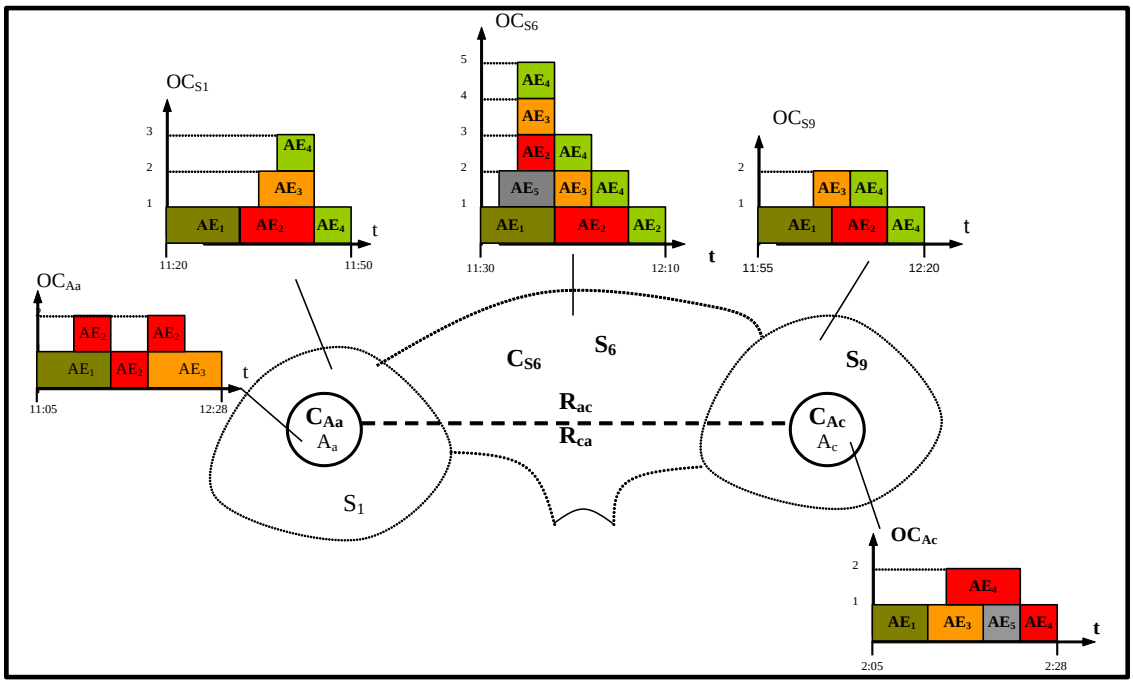

Figura 5.5: Janelas de ocupação para os elementos aeronáuticos A_a, S_1, S_6, S_9 e A_c

Dentro de certos limites estas variações podem ser aceitáveis, não provocando prejuízos aos serviços de transporte aéreo prestado. Em outras circunstâncias, o prejuízo pode ser catastrófico, quando ocorre o "efeito em cascata" e "efeito avalanche". Desta forma, devido a estes fatores, cada aeronave deve ter um tempo mínimo e máximo de permanência em cada aeroporto ou setor da infra-estrutura aeronáutica, de forma a gerar a menor interferência nos serviços de transporte aéreo prestados. Em função desta característica definem-se duas estruturas auxiliares: janela de ocupação real e relativa que serão descritas a seguir.

5.1.2 Conflitos

O problema de otimização de demanda em infra-estrutura aeronáutica, dentro do contexto de diagramas de ocupação, pode ser definido de forma similar ao conflito de tempo e capacidade apresentado em (ZWEBEN; FOX, 1994). No contexto desta pesquisa cada um destes conflitos podem ser definidos conforme a seguir:

Conflito de capacidade: cada setor do espaço aéreo apresenta pré-definida uma capacidade nominal declarada máxima de gerenciamento de aeronaves simultâneas. Este conflito ocorre quando o número de aeronaves simultâneas dentro do setor ultrapassa 80% de sua capacidade nominal declarada. A figura 5.6 apresenta este conflito.

Conflito de tempo: dentro de um diagrama de ocupação este conflito é representado pela ocupação de uma mesma posição no diagrama de ocupação, de duas ou mais aeronaves, em um mesmo instante de tempo. A figura 5.6 apresenta este conflito.

O diagrama de ocupação da figura 5.6 apresenta de forma hipotética os conflitos de capacidade e tempo gerados pelo problema de otimização em infra-estrutura aeronáutica em um setor da figura 5.2. A solução de ambos os conflitos, que representa a solução do problema estudado, será apresentado ao longo deste capítulo.

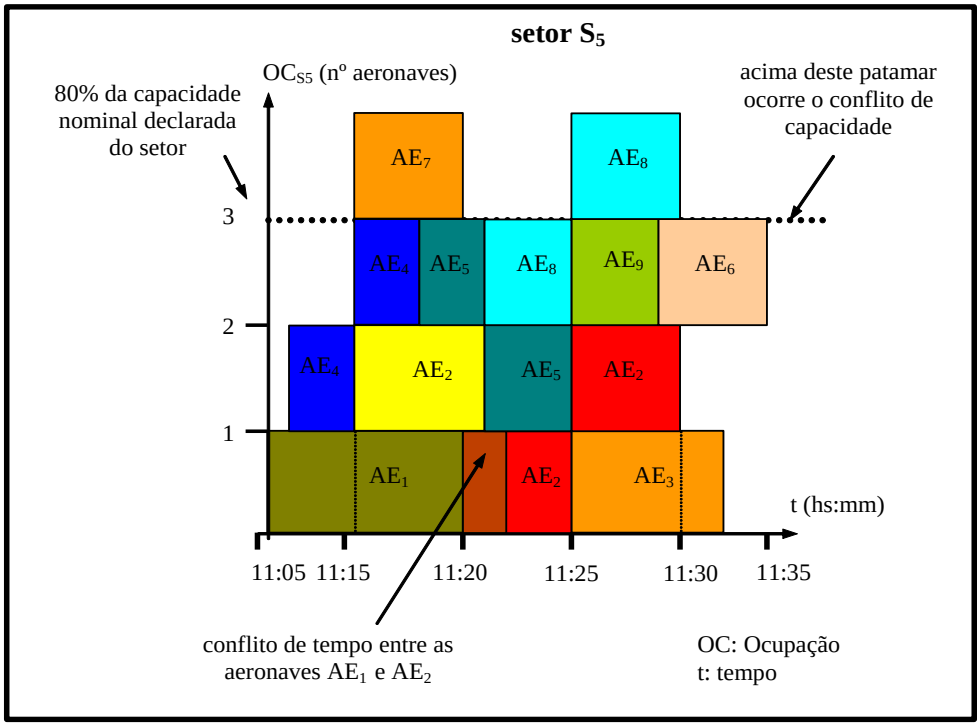

Figura 5.6: Conflito de capacidade e tempo em um diagrama de ocupação

5.1.3 Janela de Ocupação Real

A Janela de Ocupação Real corresponde ao tempo efetivo que cada aeronave ocupa em cada setor ou aeroporto da infra-estrutura aeronáutica. Ela é definida pelo instante de

tempo de entrada (t_e) e saída (t_f) de cada aeronave em cada setor S_n ou aeroporto A_n, conforme apresentado na figura 5.7.

A janela de ocupação real pode ser subdividida em intervalos de tempos discretos denominados de intervalos de amostragem Ia, que definem os instantes de tempo em que é verificada a ocupação do setor ou aeroporto, em termos de número de aeronaves. Esta verificação de ocupação é utilizada na determinação da carga de trabalho necessário para gerenciar cada setor.

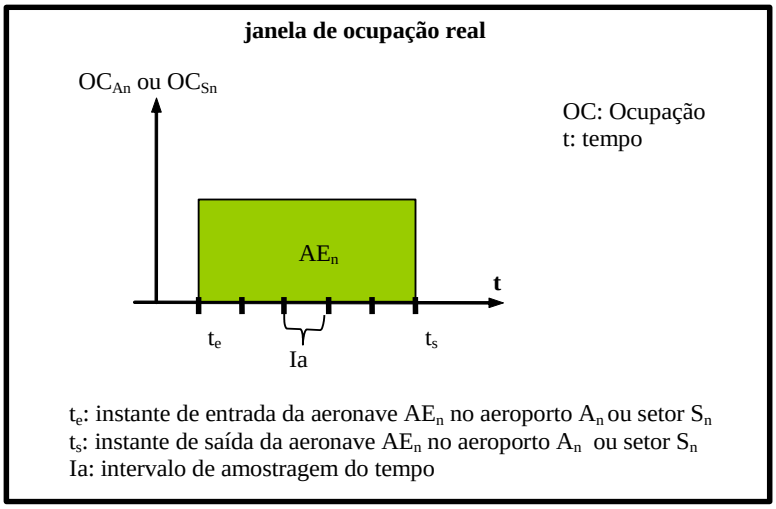

Figura 5.7: Janela de ocupação real

5.1.4 Janela de Ocupação Relativa

A janela de ocupação relativa apresenta o intervalo de tempo de permanência mínimo (tp_{min}) e máximo ($tp_{máx}$), que cada aeronave AE_n pode ocupar dentro do setor S_n ou aeroporto A_n, de forma a produzir o menor impacto nos serviços prestados pelos transportadores aéreos. A figura 5.8 apresenta a janela de ocupação relativa.

Desta forma, pode-se relacionar a janela de ocupação real e relativa através do tempo de permanência real ($\Delta Real_i$) que cada aeronave efetivamente ocupa dentro do setor ou aeroporto, através da seguinte relação:

$$tp_{mín} < \Delta Real_i < tp_{máx} \text{ (equação 1) e}$$

$$\Delta Real_i = ts_i - te_i \text{ (equação 2)}$$

Os tempos de entrada (te_i) e saída (ts_i) podem assumir diversos valores, desde que seja obedecida a equação 1. Outra questão importante é que a mudança em uma janela de

ocupação real de uma aeronave AE_n, em um setor (S_n) ou aeroporto (A_n), afeta diretamente as janelas de ocupação dos setores e aeroportos subseqüentes que serão ocupados pela aeronave. Ou seja, a rota que a aeronave AE_n irá percorrer deverá ser readequada em função da alteração da janela de ocupação. A figura 5.9 ilustra um diagrama de ocupação no qual ocorre o aumento da janela de ocupação real de uma aeronave AE_1, e a sobreposição de ocupação das aeronaves AE_1 e AE_2.

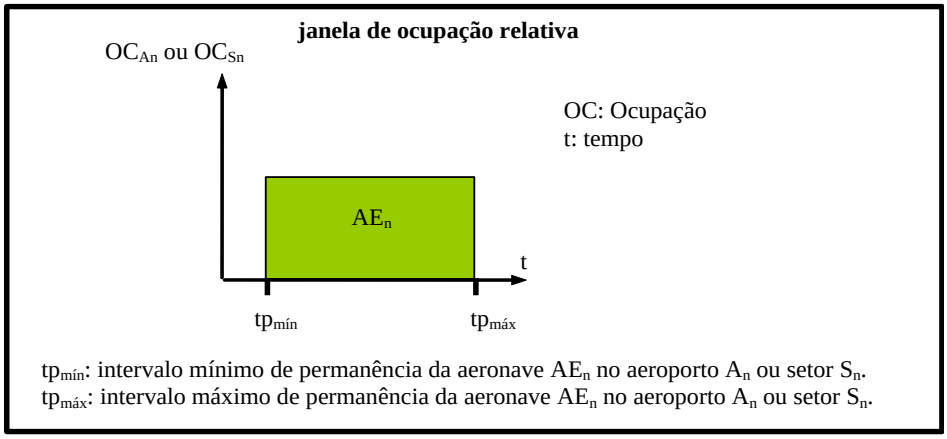

Figura 5.8: Janela de ocupação relativa

Conforme apresentado na figura 5.9, há um aumento na janela de ocupação da aeronave AE_1 no aeroporto A_a. Este aumento faz com que parte da ocupação da aeronave AE_2 seja deslocada para a primeira posição superior livre, aumentando, desta forma, a ocupação no aeroporto A_a.

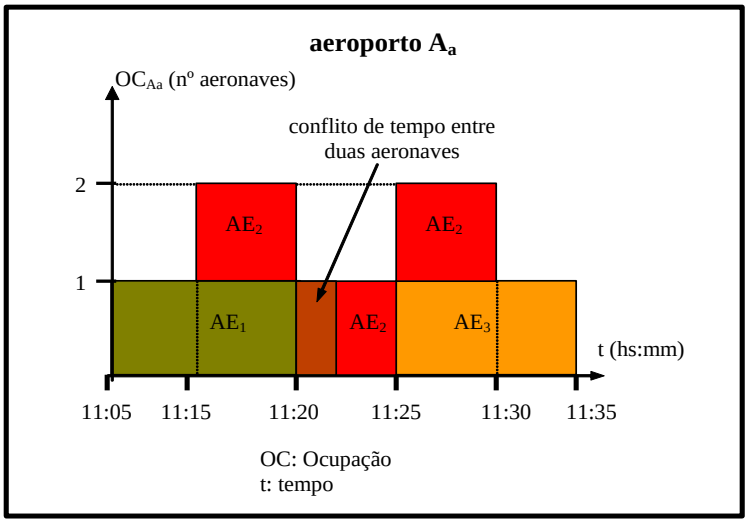

Figura 5.9: Alteração da janela de ocupação real da aeronave AE_1

Nota-se, pela figura 5.10, que o aumento na janela de ocupação da aeronave AE_1 provocou um aumento na demanda do aeroporto A_a. O fato da aeronave AE_1 permanecer maior tempo no aeroporto A_a fará com que o seu tempo de entrada e saída nos demais setores e aeroporto destino (S_1, S_6, S_9 e A_c) também se altere, ou seja, será alterado o diagrama de ocupação real destes setores e do aeroporto destino.

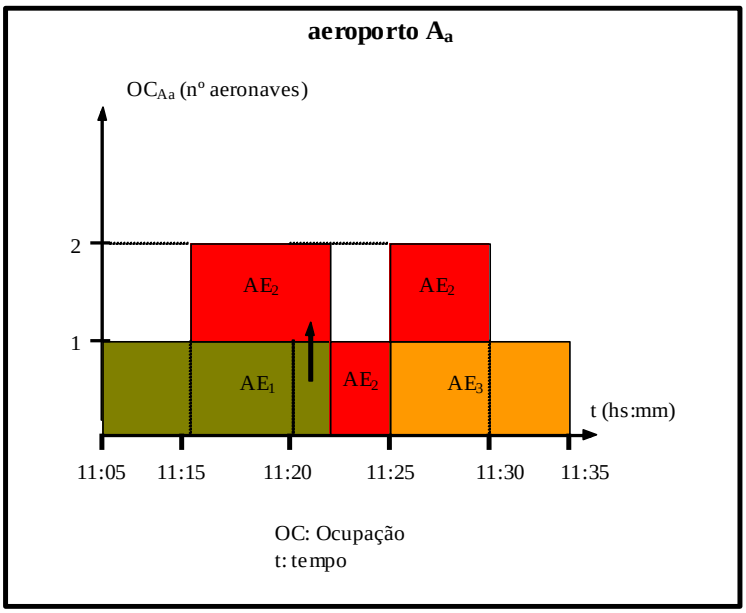

Figura 5.10: Novo diagrama de ocupação real para o aeroporto A_a

A figura 5.11 apresenta a interferência ocasionada nas janelas de ocupação dos demais setores e aeroporto destino, devido à alteração da janela da aeronave AE_1 no aeroporto A_a.

A aumento do tempo de permanência da aeronave AE_1 no aeroporto A_a, faz com que a aeronave AE_1 sofra um atraso de entrada no setor S_1, propagando igualmente este atraso para os setores S_6, S_9 e o aeroporto A_c. A figura 5.12 apresenta os novos diagramas de ocupação para os setores e aeroporto destino.

Pela figura 5.12 pode-se observar que na maioria dos diagramas de ocupação houve um aumento da demanda, nos setores e aeroportos, durante alguns intervalos de tempo devido à nova janela de ocupação da aeronave AE_1. Este fato pode fazer com que a demanda ultrapasse a capacidade nominal declarada de diversos aeroportos e setores pertencentes à rota da aeronave AE_1. Por outro lado, se a janela de ocupação da aeronave

AE_1 puder ser reduzida, poderá ocorrer à redução da demanda nos aeroportos e setores pertencentes a sua rota.

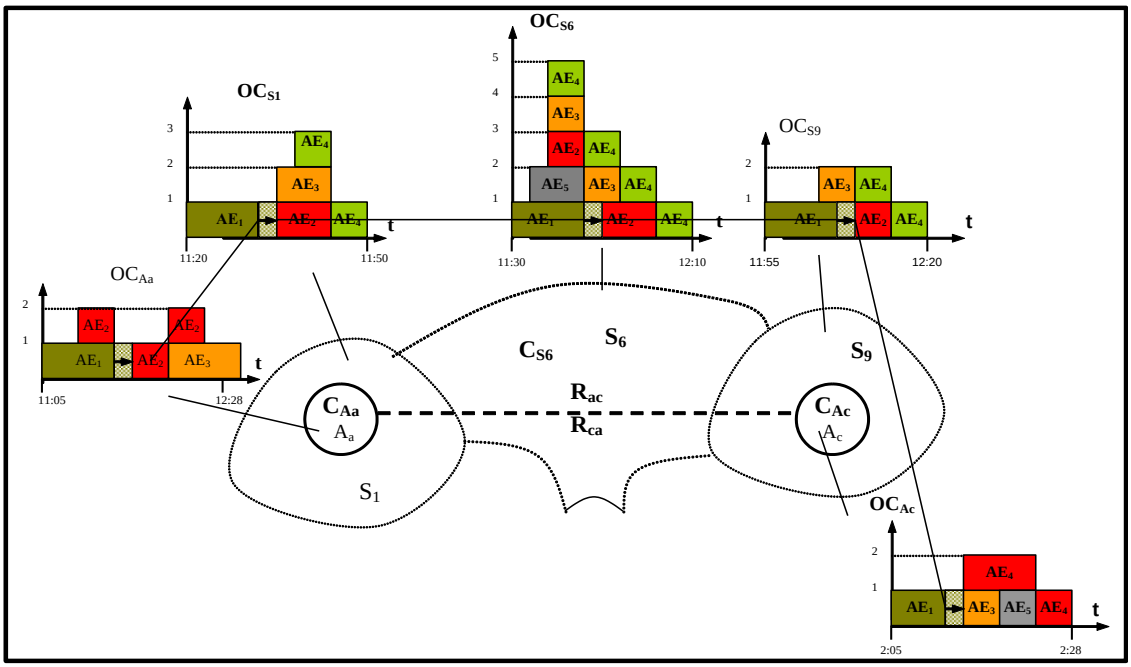

Figura 5.11: Sobreposição de ocupação em A_a, S_1, S_6, S_9 e A_c, devido a uma nova janela da aeronave AE_1

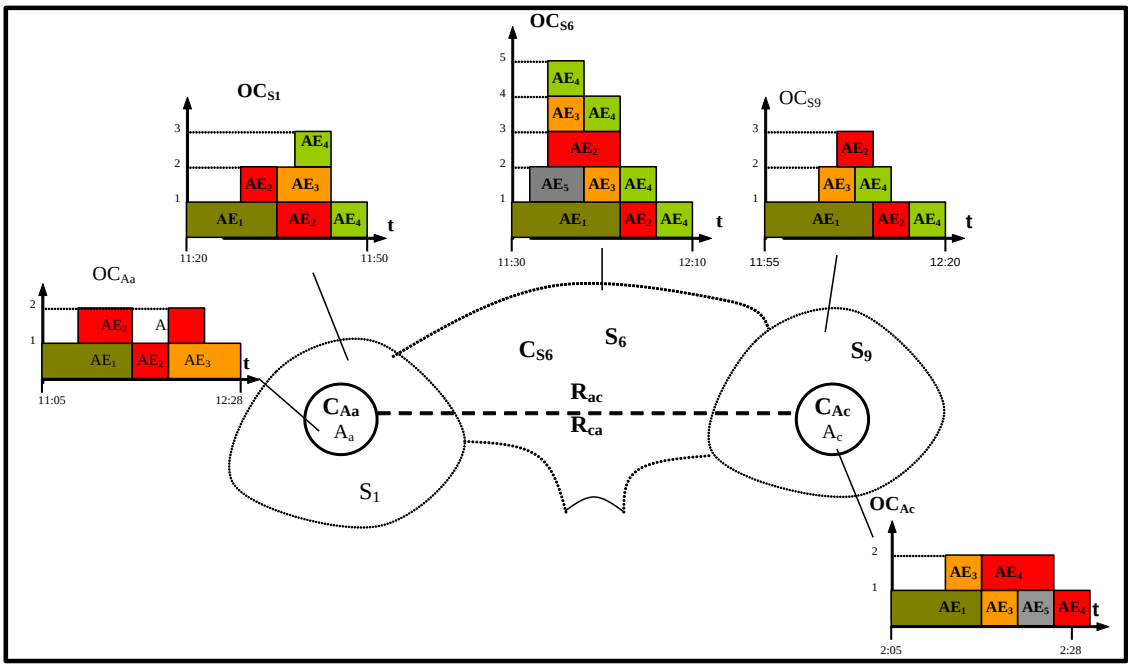

Figura 5.12: Novos diagramas de ocupação para A_a, S_1, S_6, S_9 e A_c

Desta forma, uma alteração numa das janelas de ocupação de uma aeronave pode alterar completamente as demandas nos diversos setores e aeroportos envolvidos, devendo ser verificadas se não são ultrapassadas suas capacidades nominais declaradas.

5.1.5 Cenário Aeronáutico

Neste item é descrito o cenário aeronáutico como uma seqüência de rotas, da infra-estrutura aérea, que são ocupadas pelas aeronaves (vôos) durante um período de tempo analisado. Desta forma, esse cenário aeronáutico indica a seqüência de ocupação das aeronaves dentro dos setores e aeroportos que compõem as diversas rotas em uso, num determinado período de tempo. É apresentado, a seguir, um cenário aeronáutico composto por uma seqüência de aeronaves e suas respectivas rotas de ocupação,

$$\underbrace{A_a,S_1,S_2,S_3}_{\text{vôo/rota da } AE_1},\underbrace{A_a,S_1,S_2,S_3,A_b}_{\text{vôo/rota da } AE_2},\underbrace{S_1,S_6,S_9,A_c}_{\text{vôo/rota da } AE_3},\underbrace{S_1,S_2,S_5,S_7,S_{10}}_{\text{vôo/rota da } AE_4},\underbrace{\ldots\ldots\ldots\ldots\ldots\ldots\ldots\ldots}_{\ldots\ldots},\underbrace{S_m,\ A_n}_{\text{vôo/rota da } AE_t}$$

sendo AE_1 a AE_t as aeronaves operacionais no cenário aeronáutico durante o período de tempo em análise.

5.1.6 Método de Amostragem

O método de amostragem utiliza os conceitos de instante de observação de demanda e intervalo de amostragem, definidos a seguir:

- Instante de observação de demanda: é o instante de tempo em que é obtida a demanda instantânea em todos os setores do espaço aéreo. É contabilizado o número de aeronaves em vôo nos setores da infra-estrutura considerada, sejam eles setores de área de controle terminal ou de espaço aéreo superior.
- Intervalo de amostragem: é o intervalo de tempo entre dois instantes de observação de demanda consecutivos. O intervalo de amostragem é constante para todo o período de tempo em análise da demanda da infra-estrutura aeronáutica, sendo dado por:

$$\text{intervalo de amostragem } (\Delta t) = t_2 - t_1 \quad \text{(equação 3)}$$

onde t_2 e t_1 correspondem a instantes de tempo consecutivos de observação de demanda em todos os setores da infra-estrutura aeronáutica. A figura 5.13 apresenta um exemplo de aplicação.

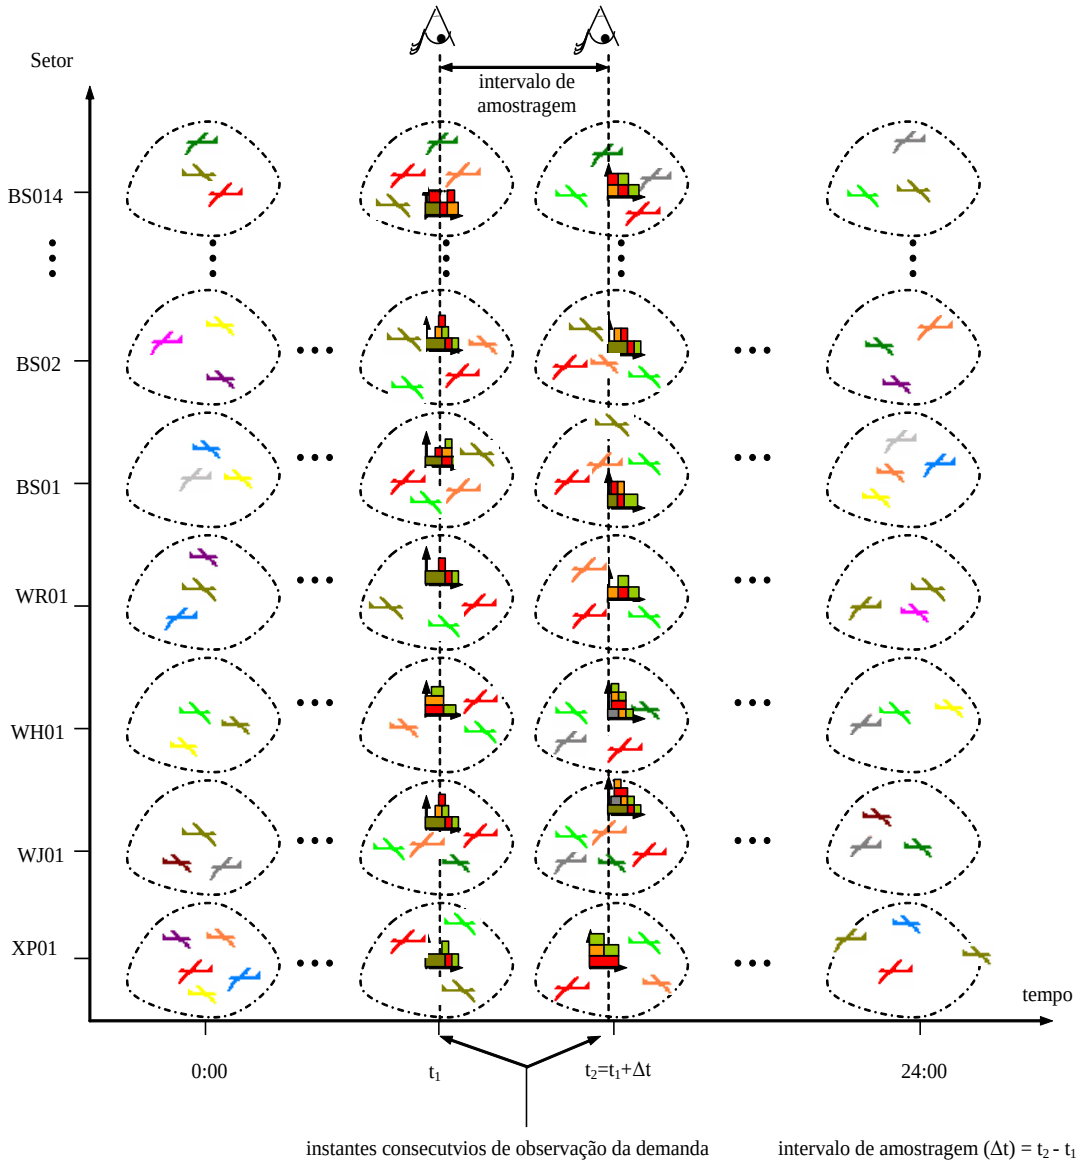

Figura 5.13: Método de amostragem

Observa-se que o intervalo de tempo de análise considerado é de um dia, no qual a demanda de todos os setores é determinada a cada intervalo de amostragem estabelecido previamente.

O método da amostragem utilizado constitui-se num artifício matemático para o levantamento e dimensionamento da demanda ao longo de período de tempo em análise, para diferentes intervalos de tempo de amostragem.

5.1.7 Discretização da Variável Tempo

A forma de discretização do tempo, no problema de otimização de demanda, apresenta interferência direta na precisão e desempenho da solução. Se os intervalos de tempo, dentro das janelas de ocupação, forem de grande granularidade, o desempenho temporal de busca do algoritmo poderá ser pequeno. O espaço de busca será tanto maior, quanto menor for a granularidade da variável tempo, e melhor será a otimização de demanda encontrada, pois mais opções dentro da janela de ocupação podem ser testadas.

O problema de otimização de demanda depende de uma prévia e minuciosa análise da discretização do tempo, procurando o equilíbrio entre eficiência algorítmica e qualidade da solução encontrada.

5.1.8 Dimensionamento do Espaço de Pesquisa

Supondo um cenário aeronáutico genérico composto de:

- *m* rotas;
- n_k número de elementos aeronáuticos (aeroportos e setores) em cada rota k;
- p_{jk} número de aeronaves no elemento aeronáutico EA_j da rota k.
- Id_{ijk} intervalo de discretização de tempo utilizado para levantamento da demanda para cada aeronave AE_i, ocupando um elemento aeronáutico EA_j, da rota k.

Portanto, o dimensionamento do espaço de pesquisa para uma rota k qualquer pode ser calculado através da seguinte equação:

$$\prod_{j=1}^{n_k} \prod_{i=1}^{p_{jk}} Id_{ijk} \qquad \text{(equação 4)}$$

Já o dimensionamento do espaço de pesquisa para todas as rotas, do cenário aeronáutico analisado, pode ser calculado através da seguinte equação:

$$\prod_{k=1}^{m} \prod_{j=1}^{n_k} \coprod_{i-1}^{p_{jk}} Id_{ijk} \qquad \text{(equação 5)}$$

A seguir são apresentadas algumas simplificações adotadas para o dimensionamento do espaço de pesquisa:

m: número de rotas do cenário aeronáutico em análise.

n: numero de elementos aeronáuticos em cada rota m indistintamente.

p: número de aeronaves em cada elemento aeronáutico indistintamente

Id: intervalo de discretização independente do elemento aeronáutico.

Tem-se que o espaço de pesquisa pode ser calculado por:

$$\prod_{k=1}^{m} \prod_{j=1}^{n} \prod_{i=1}^{p} Id = Id^{mnp} \quad \text{(equação 6)}$$

Considerando que o intervalo de discretização possa ser representado através de uma base binária (2^w), onde w corresponde ao número de bits formando este intervalo, tem-se que o espaço de pesquisa é avaliado por:

$$2^{w.m.n.p} \text{ (equação 7)}$$

Supondo que exista uma infra-estrutura aérea composta de 5 rotas, cada rota contendo 8 elementos aeronáuticos, cada elemento aeronáutico com 6 aeronaves, e cada intervalo de discretização constituído por 5 bits, o espaço de pesquisa para todas as rotas do cenário aeronáutico é dado por:

$$2^{5.5.6..8} = 2^{1200}$$

Supondo que sejam necessárias, em média, 1000 operações computacionais para contabilizar o número de aeronaves em cada rota do cenário aeronáutico, e que possa ser utilizado um moderno supercomputador (IDG NEWS SERVICE STORY, 2001) capaz de executar 100 trilhões de operações por segundo, o tempo necessário para contabilizar todas as rotas do espaço de pesquisa será:

$$\frac{2^{1200}.10^{3}}{10^{11}} \approx 1{,}7218.10^{353} \quad \text{segundos}$$

ou seja, aproximadamente 53, 10^{344} anos.

Como pode ser observado, mesmo para um problema de menor dimensão o consumo computacional pode ser tão elevado, que torna-se inviável o cálculo de todos os cenários aeronáuticos possíveis. Esta característica é um dos fatores que caracterizam um problema NP-Completo (HAUPT R. L.; HAUPT S. E., 1998).

5.2 Caracterização do Modelo de Otimização

O principal objetivo da otimização é encontrar o melhor cenário aeronáutico global, válido para todas as aeronaves, elementos aeronáuticos e rotas, apresentando a menor carga de trabalho de gerenciamento e, se possível, o menor atraso provocado.

Desta forma, pretende-se encontrar um conjunto de diagramas de análise de situação (um diagrama para cada elemento da infra-estrutura aérea estudada), considerando todo o cenário aeronáutico. A ocupação de cada setor do espaço aéreo, seja de área de controle terminal ou espaço aéreo superior, não deve ser excedida em 120% de sua capacidade nominal declarada (patamar de saturação aceitável).

5.2.1 Parâmetros de Entrada do Modelo de Otimização

Os parâmetros de entrada do modelo de otimização proposto são:

- Descrição da infra-estrutura aérea
  - Rotas (identificação e seqüência de cada aeroporto e setor de cada rota) que compõem o cenário aeronáutico em análise.
  - Capacidade nominal declarada de cada elemento aeronáutico que compõem o cenário aeronáutico em análise.
- Tempos de permanência nominal de cada aeronave em cada elemento aeronáutico (aeroportos e setores) do cenário aeronáutico no período de tempo em análise, sem considerar nenhum atraso.
- Estado inicial do cenário aeronáutico contendo as posições de todas as aeronaves ao longo de todos os elementos aeronáuticos.
- Período de análise do cenário aeronáutico em unidades de tempo de simulação.
- Intervalo de discretização: intervalo de tempo entre observações de demanda durante a simulação do cenário aeronáutico em análise.
- Janelas de tempo: define a janela de ocupação relativa a cada aeronave em cada elemento do cenário aeronáutico em análise, apresentando o seguinte formato:
  - Áreas de controle terminal: janela inicia-se desde δ% a menos, até η % a mais do tempo de permanência nominal definido para cada aeronave dentro da cada setor da área terminal, sendo $\delta < \eta$ preferencialmente.
  - Setores do espaço aéreo superior: janela inicia-se desde τ % a menos, até τ % a mais do tempo de permanência nominal de cada setor.

  A janela de tempo em áreas terminais é assimétrica, permitindo preferencialmente mais desacelerações do que acelerações, indistintamente para aeronaves em

decolagem ou aterrisagem. Esta medida foi adotada pois a situação de aterrisagem é mais crítica, na medida que as aeronaves estão cada vez mais próximas dos aeroportos destino. Estas áreas apresentam, normalmente, maior concentração de aeronaves para aterrisagem, sendo que a aceleração excessiva poderia diminuir os seus respectivos níveis de segurança dentro destas áreas (SIEWERDT, 2003b). Na decolagem de aeronaves ocorre preferencialmente mais acelerações das aeronaves até atingir-se o espaço aéreo superior, no qual a velocidade é normalmente constate (velocidade de cruzeiro).

- Tempos de permanência em aeroportos: atraso no horário de decolagem, em relação ao horário nominal (padrão) de decolagem .
- Tempos de entrada e saída de vôos externos: dada uma infra-estrutura aeronáutica para análise, o modelo permite que apenas uma parte desta infra-estrutura seja considerada para analise. Para tornar esta análise mais próxima de uma situação real, o modelo admite que aeronaves possam entrar e sair do cenário aeronáutico em analise. Assim, a infra-estrutra aeronáutica, externa ao cenário aeronáutico analisado, pode ser considerada como uma fonte/sorvedouro de aeronaves. Desta forma, é associada uma janela de tempo de ocupação, relacionadas ao tempo em que as aeronaves entram e saem deste setor externo.

5.2.2 Dimensionamento dos Parâmetros a serem Otimizados

A função objetivo (de aptidão) é o principal parâmetro a ser otimizado, direcionador do processo de otimização. A função objetivo auxiliar é um parâmetro secundário, auxiliar, utilizado apenas ao final do processo de otimização, ou seja, não participa do processo de otimização dos algoritmos genéticos.

a) Função Objetivo

O que se deseja ao final do processo de otimização é encontrar a melhor distribuição de demanda, que minimize a carga de trabalho de gerenciamento global em todo o cenário aeronáutico durante o período em análise. Assim, a função objetivo (FO) também denominada de função de aptidão é definida em relação à carga de trabalho de gerenciamento global do cenário aeronáutico, privilegiando o requisito de segurança (*safety*).

$$FO_{\max imizar} = \frac{1}{WL_{cenário aeronáutio}} \text{ (equação 8)}$$

Deve-se maximizar a função objetivo.

a.1) Carga de Trabalho de Gerenciamento do Cenário Aeronáutico

A carga de trabalho (*Workload* - WL) de gerenciamento global do cenário aeronáutico é dada pela equação a seguir:

$$WL_{cenário aeronáutio} = \sum_{1}^{n} WL_{Setor_n} \text{ (equação 9)}$$

Sendo $WLsetor_n$ igual à carga de trabalho de gerenciamento do setor n, seja ela um setor de área terminal ou espaço aéreo superior.

a.1.1) Carga de Trabalho de Gerenciamento dos Setores

A carga de trabalho de gerenciamento dos setores é calculada conforme a seguir:

$$WL_{setor_n} = \sum_{t_1}^{t_2} penalidade * WL_{instantâneo do setor n} \text{ (equação 10)}$$

sendo t_1 e t_2 o intervalo de tempo de simulação considerado na análise de demanda.

A carga de trabalho de gerenciamento em cada setor da infra-estrutura aeronáutica utiliza dois parâmetros. O primeiro parâmetro é a carga de trabalho de gerenciamento instantânea no setor. O segundo é a penalidade, que pune soluções inviáveis durante o processo de otimização. Ambos parâmetros são detalhados a seguir.

a.1.2) Carga de Trabalho Instantâneo em cada Setor

A carga de trabalho de gerenciamento instantânea adotada é dada por:

$$WL_{instantâneo do setor n} = B_1^{ES_n} * B_2^{TDE_n} \text{ (equação 11)}$$

Sendo:

ES_n = estouro do setor S_n, ou seja, valor da demanda (número de aeronaves) acima de 80% da capacidade nominal declarada do setor *n*.

TDE_n = tempo de duração do estouro ES_n.

As bases B_1 e B_2 devem ser respectivamente estimadas para ES_n e TDE_n, partindo-se do princípio que, quando ES_n for igual a 120% da capacidade nominal declarada do setor e sua duração TDE_n for igual a 12 minutos, deverá ter-se o valor de WL igual a 50 (valor escolhido arbitrariamente) para o setor *n*. Para cada setor de capacidade diferente existirá

um par de bases B_1 e B_2, que em conjunto com os valores de ES_n e TDE_n, definem o valor de $WL_{\text{instantâneo do setor n}}$ em cada instante do setor n.

A base inicial para a estimativa $WL_{\text{instantâneo}}$ por setor foram obtidas em função de dois estudos (SIEWERDT, 1991) e[1]:

- Estudo realizado pela MBB (*Messerschmidt, Boelkow & Blohm*), grupo com atuação diversificada no campo aeronáutico, e incorporado pela DASA (*Deutsche Aerospace*). Neste estudo, denominado de "Metodologia MBB", é proposto um modelo para a determinação de capacidade de controle de um ATC. Nesta metodologia, a estimativa da carga de trabalho de gerenciamento é realizada segundo um crescimento geométrico. Assim, em uma dada situação existe um certo número de aeronaves, em um setor em que se adota a carga de trabalho de gerenciamento igual a 1. Uma aeronave adicional neste cenário aeronáutico corresponderia a uma carga de trabalho de gerenciamento igual a 2. Mais uma aeronave adicional corresponderia à carga de trabalho de gerenciamento igual a 4, e assim sucessivamente. Um valor de carga de trabalho de gerenciamento igual a 40, segundo o estudo da MBB, era considerada elevada para um controlador de tráfego aéreo.

  Nesta análise, considera-se o número de aeronaves excedentes, a partir de uma situação considerada normal, como fator principal para estimativa de carga de trabalho de gerenciamento em cada setor da infra-estrutura aeronáutica.
- Outro estudo realizado pela CAA (*Civil Aviation Authority*) Inglesa define que um tráfego é suportável até 120% da capacidade nominal declarada de cada setor, durante 10% do tempo total de trabalho. Considerando que um controlador de tráfego aéreo trabalhe em turnos de 2 horas, ele poderia suportar 120% da capacidade nominal declarada durante no máximo 12 minutos (ICAO 9426, 2002) e (SIEWERDT, 2003a). Ou seja, neste estudo realizado pela CAA Inglesa é levado em consideração tanto o tamanho do estouro, ou seja, número de aeronaves excedentes além da capacidade nominal declarada de cada setor, bem como o tempo de duração deste estouro.

[1] SIEWERDT E., **Reunião sobre a pesquisa**, Escola Politécnica da Universidade de São Paulo, São Paulo, 10 junho 2003 (Informações verbais).

A estimativa da carga de trabalho de gerenciamento, principalmente quando associado a controladores de tráfego aéreo, engloba diversos fatores cognitivos, tais como os relacionados à percepção visual e auditiva, memorização, atenção, entre outros (HUTCHIND, 1995) e (NATIONAL INSTITUTE OF MENTAL HEAKTH, 1994). Desta forma, a atividade destes profissionais é de grande complexidade, exigindo uma carga de trabalho de gerenciamento mental extremamente elevada, tornando a sua medida bastante complexa e subjetiva, necessitando o envolvimento em diversas áreas do conhecimento humano.

Em função desse contexto, esse aspecto merece ser pesquisado em trabalhos específicos. Estas pesquisas podem ser de grande valia quando incorporadas, futuramente, ao presente trabalho de pesquisa. Desta forma, a análise em profundidade da carga de trabalho de gerenciamento foge do escopo deste trabalho de pesquisa. Neste trabalho de pesquisa foi discutido e adotado o que se considerou uma boa estimativa da carga de trabalho de gerenciamento. Para um melhor detalhamento deste assunto poderá ser consultado (ICAO 9426, 2002) e (ATHENES et al., 2002).

Na estimativa da carga de trabalho de gerenciamento, adotada nessa pesquisa, procurou-se enfatizar três fatores relevantes:

- Tamanho do estouro: número de aeronaves que excedem a 80% da capacidade nominal declarada de cada setor.
- Tempo de estouro: duração do estouro desde o seu início até o seu final. Considera-se o período de tempo em que o controlador de tráfego aéreo é submetido a uma carga de trabalho de gerenciamento considerada fora da normalidade (acima de 80% da capacidade nominal declarada de cada setor controlado).
- Tamanho dos setores: setores de tamanhos diferentes devem ser considerados separadamente quando submetidos a estouros de mesmo tamanho. Um estouro de 3 aeronaves em um setor de capacidade nominal declarada igual a 7, em média, deve apresentar carga de trabalho de gerenciamento maior do que esse mesmo estouro em um setor de capacidade nominal declarada igual a 20.

A estimativa utilizada para carga de trabalho de gerenciamento pode ser considerada como sistêmica, macroscópica, pois não leva em consideração detalhes das tarefas e

procedimentos realizados dentro de um ATC, turnos de trabalho dos controladores de tráfego aéreo entre outros fatores. Estes fatores podem ser considerados como microscópicos.

a.1.3) Penalidade

O objetivo deste parâmetro é penalizar soluções inviáveis beneficiando na obtenção de soluções mais viáveis. Deve-se penalizar casos em que não se tenha a garantia de se obter uma solução viável, seja pela dificuldade de encontrá-la, seja por ela simplesmente não existir.

No caso do modelo de otimização de demanda procura-se facilitar a obtenção de cenários aeronáuticos que apresentem, em todos os setores, demanda abaixo da linha de saturação aceitável (120% da capacidade nominal), devendo-se penalizar os cenários aeronáuticos que apresentem estouros acima desta linha. Esta medida é uma forma de facilitar aos algoritmos genéticos, a separação e classificação dos cromossomos mais aptos.

Um fator fundamental a ser observado é que o modelo de otimização de demanda em infra-estrutura aeronáutica trate o problema de otimização de desbalanceamento entre demanda e capacidade nominal declarada dos setores de forma sistêmica. As penalidades foram definidas em faixas, de acordo com a carga de trabalho de gerenciamento, conforme apresentado a seguir:

$$\text{penalidade} = \begin{cases} 1, \text{ se } WL_{\text{instantâneo do setor n}} \leq 1 \\ \nu, \text{ se } 1 < WL_{\text{instantâneo do setor n}} \leq 50 \\ \rho, \text{ se } WL_{\text{instantâneo do setor n}} > 50 \end{cases} \qquad \text{(equação 12)}$$

Adota-se penalidade igual a 1 quando não houver estouro em relação à capacidade nominal declarada do setor, penalidade igual a ν quando o estouro estiver entre as linhas de congestionado e saturação aceitável e penalidade igual a ρ, quando o estouro estiver acima de linha de saturação aceitável (supersaturação). Deve-se lembrar que ρ ser

significativamente maior que ν, de forma a permitir uma maior diferenciação entre cromossomos válidos e inválidos.

A carga de trabalho (WL – *Workload*) de gerenciamento para um setor *n* é $WL_{setor\ n}>1$ a partir de 80% de ocupação da capacidade nominal declarada deste setor (setor congestionado).

Durante o processo de otimização de otimização, a cada instante de observação de demanda (Método de Amostragem), o estouro de capacidade de cada setor *n* é calculado conforme a seguir:

$$ES_n = D_{tn} - 80\%\ CND_n \text{ (equação 13)}$$

Sendo:

ES_n : Estouro de capacidade do setor *n*.

D_{tn}: Demanda no instante de observação *t* do setor *n*.

CND_n: capacidade nominal declarada do setor *n*.

Portanto, a carga de trabalho final, para um setor *n*, será:

$$WL_{setor\ n} = \begin{cases} 1 & \text{(se não houver estouro de capacidade no setor } n\text{)} \quad \text{(equação 14)} \\ \sum_{t_1}^{t_2} penalidade * WL_{instantâneo\,do\,setor\,n} & \text{(se houve estouro de capacidade do setor } n\text{)} \end{cases}$$

Para um cenário aeronáutico em que todos os seus setores não estejam congestionados, terá como carga de trabalho global de gerenciamento:

$$WL_{cenário\,aeronáutio} = N \text{ (equação 15)}$$

sendo *N* igual ao número total de setores do cenário aeronáutico analisado.

b) Função Objetivo Auxiliar

O objetivo desta função é classificar os cenários aeronáuticos obtidos ao final do processo de otimização (última geração dos algoritmos genéticos) em relação ao "custo de permanência em vôo" das aeronaves. Este custo de permanência em vôo é definido em relação aos atrasos globais gerados nos aeroportos e setores do cenário aeronáutico, sendo calculado pela seguinte equação:

$$FO\ Auxiliar = \sum_1^m AS_m + 1{,}3(\sum_1^n AVD_n + \sum_1^p AEA_p \text{ (equação 16)}$$

Sendo:

AS_m: atrasos em solo no aeroporto *m* (válido somente para os vôos com origem dentro do cenário aeronáutico analisado) = (horário de entrada efetiva do vôo na área terminal) – (horário de entrada nominal do vôo na área terminal).

AVD_n: atrasos em vôo das aeronaves dentro do setor *n*.

$$AVD_n = \begin{cases} 0, \text{ se } t_{pr} - t_{pn} < 0 \\ t_{pr} - t_{pn} \end{cases} \quad \text{(equação 17)}$$

onde:

t_{pr}: tempo de permanência real dos vôos no setor *n*

t_{pn}: tempo de permanência nominal dos vôos no setor *n*

AEA_p: atrasos de entrada e saída das aeronaves no setor *p* (válido para vôos com origem externa ao cenário aeronáutico).

$$AEA_p = \begin{cases} 0, \text{ se } t_{pr} - t_{pn} < 0 \\ t_{pr} - t_{pn} \end{cases} \quad \text{(equação 18)}$$

O fator 1,3 utilizado na função objetivo auxiliar adota como hipótese que o custo dos atrasos em vôo são, em média, 30% maiores que os custos dos atrasos em solo[1]. Assim, após a seleção dos melhores cenários aeronáuticos (cromossomos), através da função objetivo, é aplicada sobre estes a função objetivo auxiliar, com o objetivo de estimar o custo de permanência em vôo de cada cenário aeronáutico otimizado. Assim, quanto menor a função objetivo auxiliar, melhor será o cenário aeronáutico em relação a função objetivo auxiliar, pois menor serão os atrasos das aeronaves.

5.2.3 Influência do Intervalo de Amostragem na Carga de Trabalho

Para facilitar o entendimento da determinação da carga de trabalho de gerenciamento instantânea, considera-se o setor com diagrama de análise de situação (gráfico de demanda) apresentado na figura 5.14.

[1] SIEWERDT E., **Reunião sobre a pesquisa**, Escola Politécnica da Universidade de São Paulo, São Paulo, 10 junho 2003 (Informações verbais).

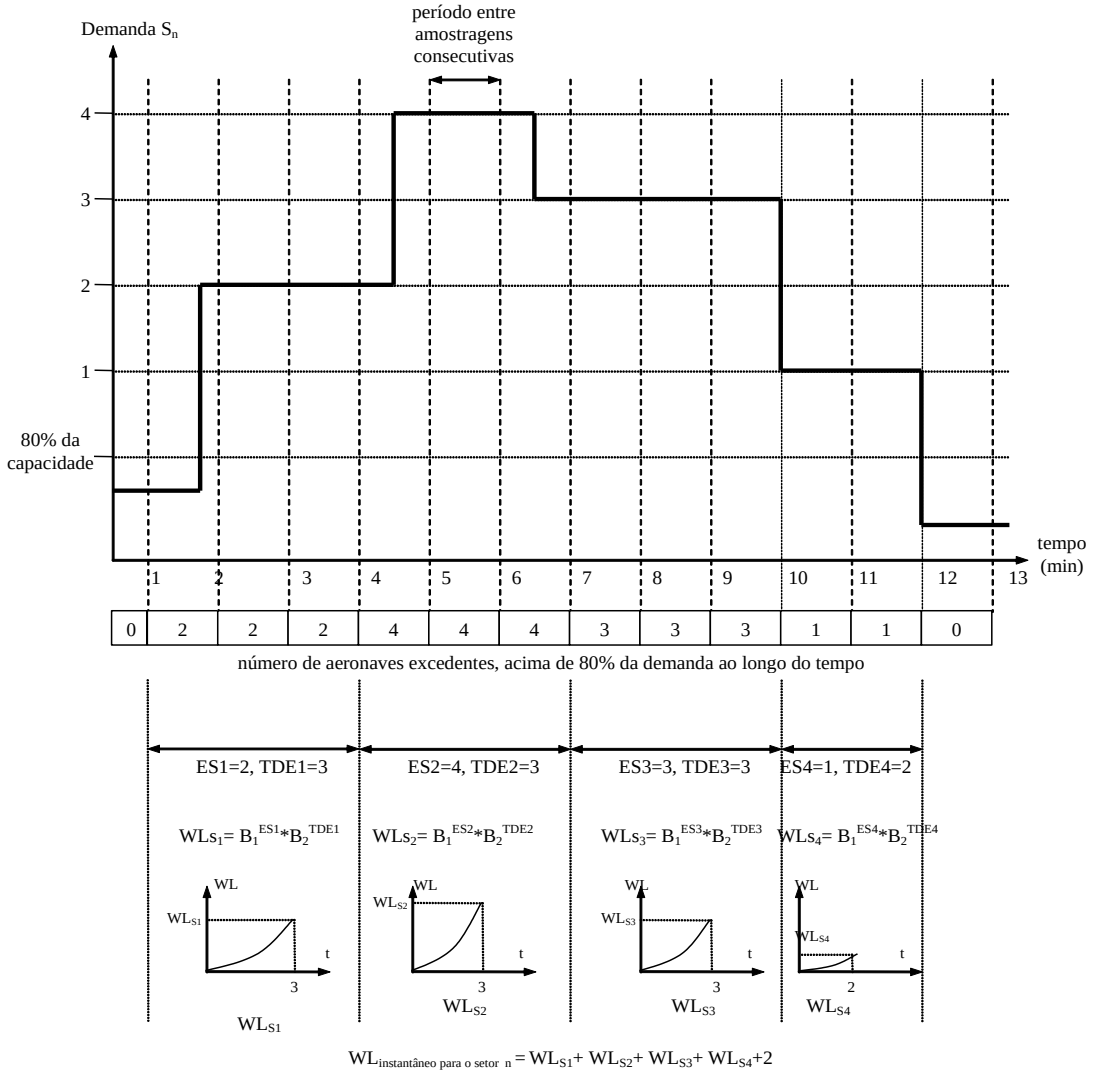

Figura 5.14: Determinação da carga de trabalho de gerenci. instantânea para um setor

Observa-se que a carga de trabalho de gerenciamento é determinada em função da quantidade de aeronaves que excede 80% da capacidade nominal declarada do setor (ES) e do tempo de duração que esta demanda é excedida (TDE). A carga de trabalho de gerenciamento é contabilizada por trechos (intervalos de amostragem), no qual ES se mantém constante e TDE é determinado nestes intervalos de amostragens. Quando ES é alterado para um valor inferior ou superior, começa-se novamente a contabilizar TDE.

Observe na figura 5.14 os gráficos das cargas de trabalho instantâneos (WL_{S1} a WL_{S4}) produzidos pela função $WLs_n= B_1^{ESn}*B_2^{TDEn}$, sendo B_1 e B_2 específicos para cada setor *n* de tamanho diferente. Supor que a demanda apresentada esteja entre os patamares de

congestionamento e saturação aceitável e a penalidade utilizada seja igual a ν. Assim, a carga de trabalho de gerenciamento do setor n será igual a $WL_{setor\ n} = \nu.(WL_{S1} + WL_{S2} + WL_{S3} + WL_{S4})$.

Observando-se a figura 5.14 pode-se notar que existe um erro devido à taxa de amostragem. Quando existe a transição de demanda entre períodos de amostragem, observa-se que a contabilização é realizada de forma que a demanda considerada é maior que o valor da demanda real.

Esta forma de contabilização da carga de trabalho de gerenciamento foi adotada de forma a, quando houver um erro, ser sempre para um valor superior de carga de trabalho real, privilegiando-se assim os requisitos de segurança (*safety*).

Desta forma, quanto menor for intervalo de amostragem maior será precisão da demanda considerada, conforme apresentado na figura 5.15.

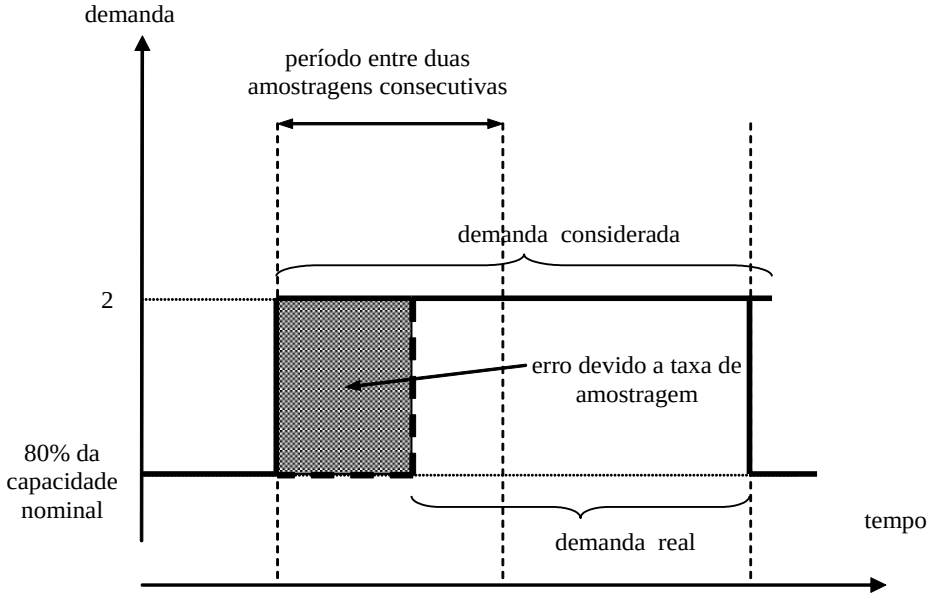

Figura 5.15: Erro devido ao intervalo de amostragem

Como pode ser observado na figura 5.16 o erro entre a demanda real e a contabilizada diminui, com a diminuição do intervalo de amostragem.

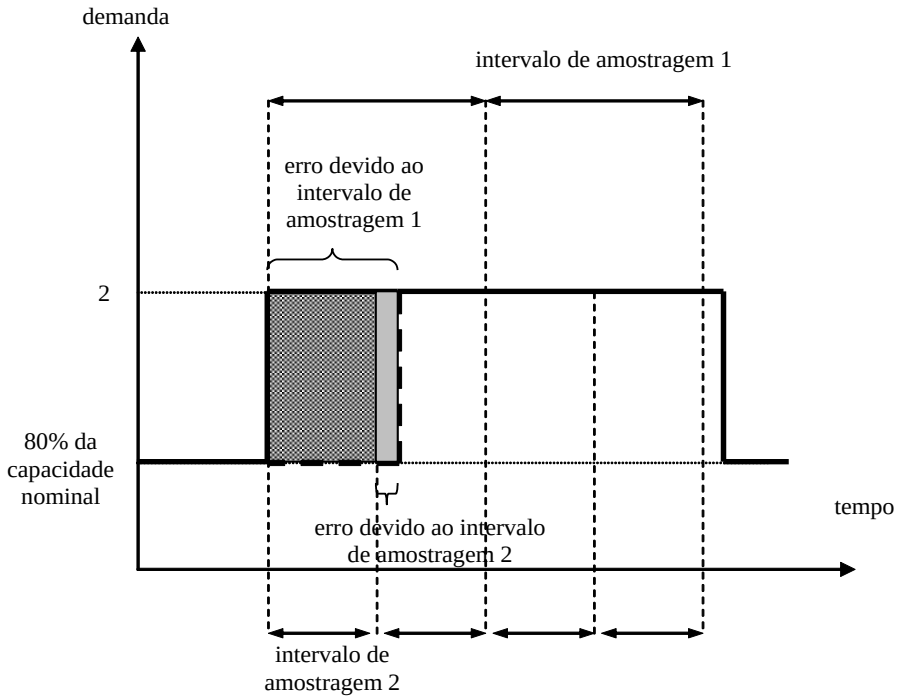

erro devido ao intervalo de amostragem 1 > erro devido taxa de amostragem 2

Figura 5.16: Diminuição de erro com a diminuição do intervalo de amostragem

5.2.4 Descrição do Cromossomo Utilizado

O cromossomo proposto, representativo do cenário aeronáutico, é composto por uma seqüência de setores, podendo iniciar em um aeroporto e terminando em outro (no caso de rotas internas), sendo a seqüência destes ocupados pela mesma aeronave AE_i, ou seja, ocupando a rota R_n dentro do cenário aeronáutico. O conjunto de todas as aeronaves AE_i (demanda) contidas em todas as rotas dentro do cenário aeronáutico, forma o cenário aeronáutico analisado. O cromossomo proposto representa uma solução possível para o problema de otimização. Dependendo do tempo de ocupação de cada aeronave AE_i, em cada aeroporto ou setor, poderá existir um cenário aeronáutico diferente. A figura 5.17 apresenta o cromossomo utilizado no modelo de otimização de demanda.

Dentro do cromossomo cada aerporto A_n ou setor S_n corresponde a um conjunto de bits referente à janela de ocupação de cada aeronave AE_i dentro do aeroporto A_n ou setor S_n. O valor correspondente deste conjunto de bits representa o tempo real que a aeronave AE_i levará para atravessar o setor S_n, ou então, corresponderá ao atraso na decolagem no aeroporto A_n. Este conjunto de bits poderá variar entre um tempo mínimo (t_{min}) e um

tempo máximo (t_{max}) estimado para a aeronave AE_i cruzar o setor S_n. ou então, para ocupar o aeroporto A_n. Sobre esse cromossomo, em cada setor S_n ou aeroporto A_n, são aplicados dois operadores genéticos: permutação e mutação.

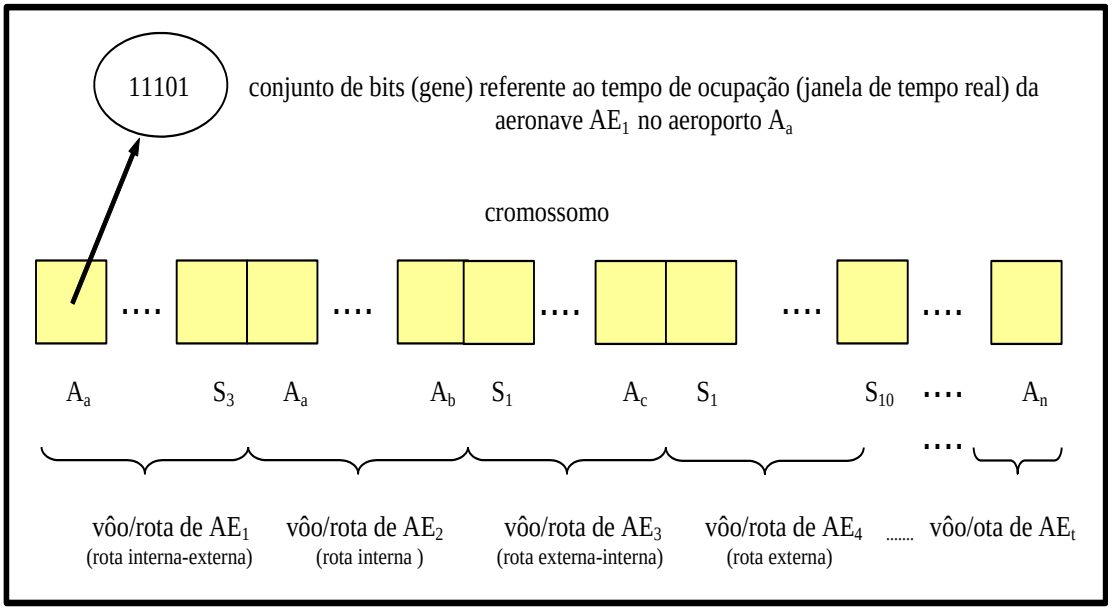

Figura 5.17: Cromossomo para o modelo de otimização de demanda

Fato importante a ser observado é que de forma genérica o modelo de demanda proposto pode acomodar, conforme apresentado, também otimizações de ocupação de aeronaves em aeroportos. Deve ser destacado que o enfoque deste trabalho de pesquisa está relacionado apenas as otimizações de aeronaves em vôo (em setores de áreas de controle terminal e espaço aéreo superior), e atrasos na decolagem de aeroportos. Deve-se destacar que enfoque por si só é complexo, além de que o gerenciamento, logística e otimizações de aeronaves em aeroportos é complexo, sendo que muitas vezes resolvidos em tempo real merecendo, portanto, uma nova linha de pesquisa.

5.2.4.1 Operador Permutação

A partir da seleção dos cromossomos reprodutores selecionados pelo processo de reprodução, os mesmos são tomados dois a dois, e aplicado o operador permutação em um ponto aleatório em cada um dos pares de cromossomos formados, conforme a figura 5.18. Observe que os cromossomos descendentes 1' e 2' apresentam, cada um deles, parte da composição genética dos cromossomos ascendentes 1 e 2.

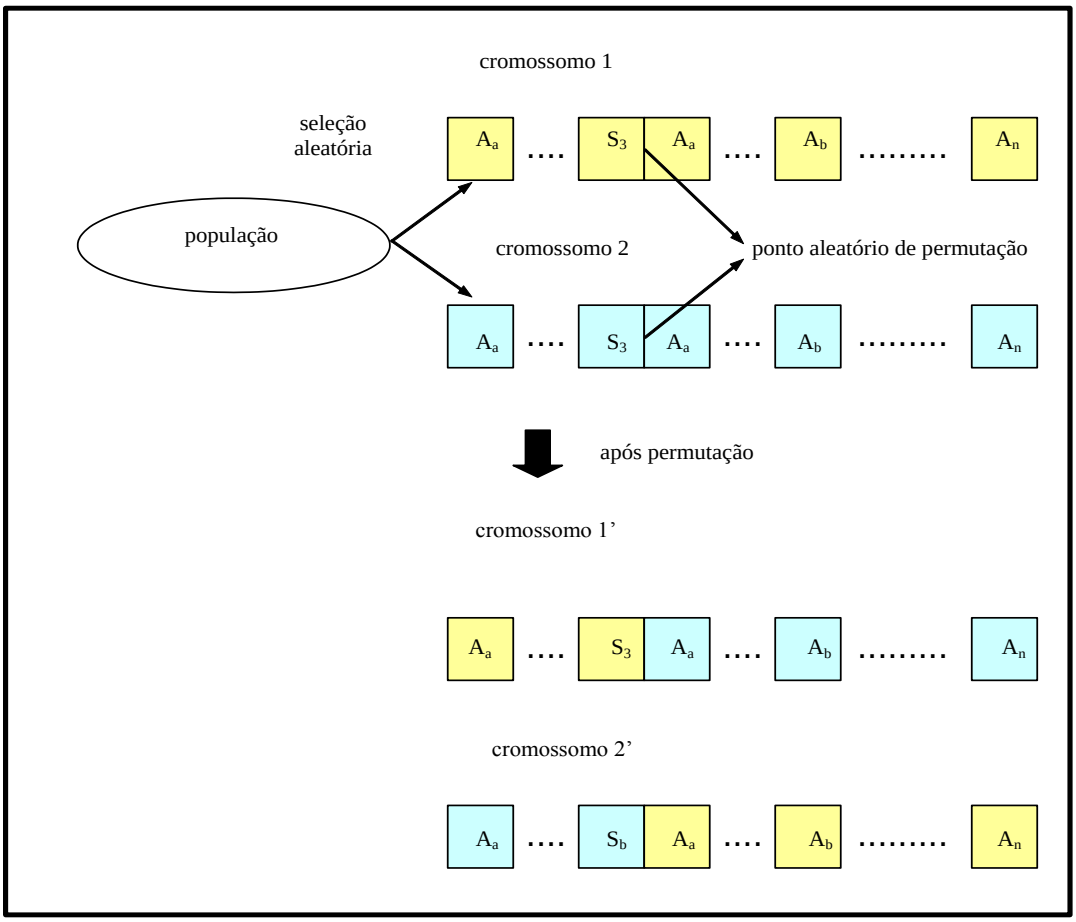

Figura 5.18: Aplicação do operador permutação

5.2.4.2 Operador Mutação

A partir dos cromossomos descendentes gerados pelo operador permutação, seleciona-se uma porcentagem destes, também de forma aleatória, e aplica-se o operador mutação em um gene aleatório (em um bit também escolhido aleatoriamente dentro do gene), que refere-se ao tempo de permanência de uma aeronave AE_i, dentro de um setor S_n. Esta seleção de um gene aleatório é realizada para cada cromossomo selecionado para aplicação do operador mutação. Assim, obtém-se novos tempos de ocupação da aeronave AE_i dentro do setor S_n, respeitando-se os intervalos de tempo adotados. Esta aplicação do operador mutação em uma única posição dentro do gene é também denominada de mutação simples.

A figura 5.19 apresenta a seleção do cromossomo 2' para aplicação do operador mutação. Em seguida é selecionado, de forma aleatória, um bit do cromossomo e

aplicado o operador mutação (mutação simples), gerando-se assim o cromossomo descendente 2’’.

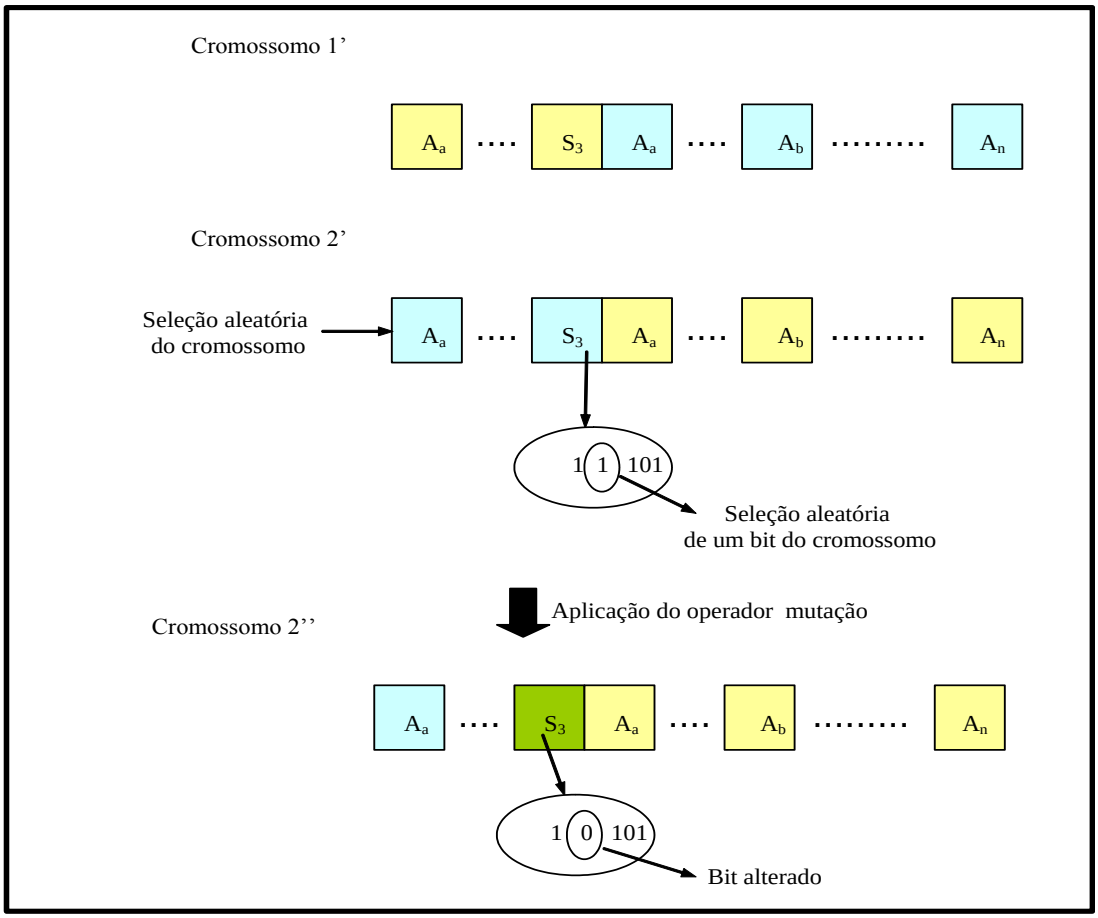

Figura 5.19: Aplicação do operador mutação

A posição do cromossomo 2’’ onde ocorreu a mutação corresponde agora a um novo tempo de ocupação da aeronave AE_i dentro do setor S_3. Este novo tempo de ocupação da aeronave AE_i dentro do setor S_b poderá ser um tempo ainda não considerado no processo de otimização. Assim, o operador mutação permite explorar novos pontos do espaço de pesquisa, que não podem ser obtidos através do operador permutação.

A seqüência de aplicação do operador permutação seguido do operador mutação, que representa o ciclo de reprodução, ocorre em cada uma das gerações dos algoritmos genéticos.

5.2.5 Determinação do Cenário Aeronáutico Real

Um cromossomo representa um cenário aeronáutico sugerido para ser executado no dia de realização dos vôos. Para abstrair os tempos de permanência de cada aeronave AE_i dentro de cada setor S_n é considerado o cenário aeronáutico hipotético apresentado na figura 5.20.

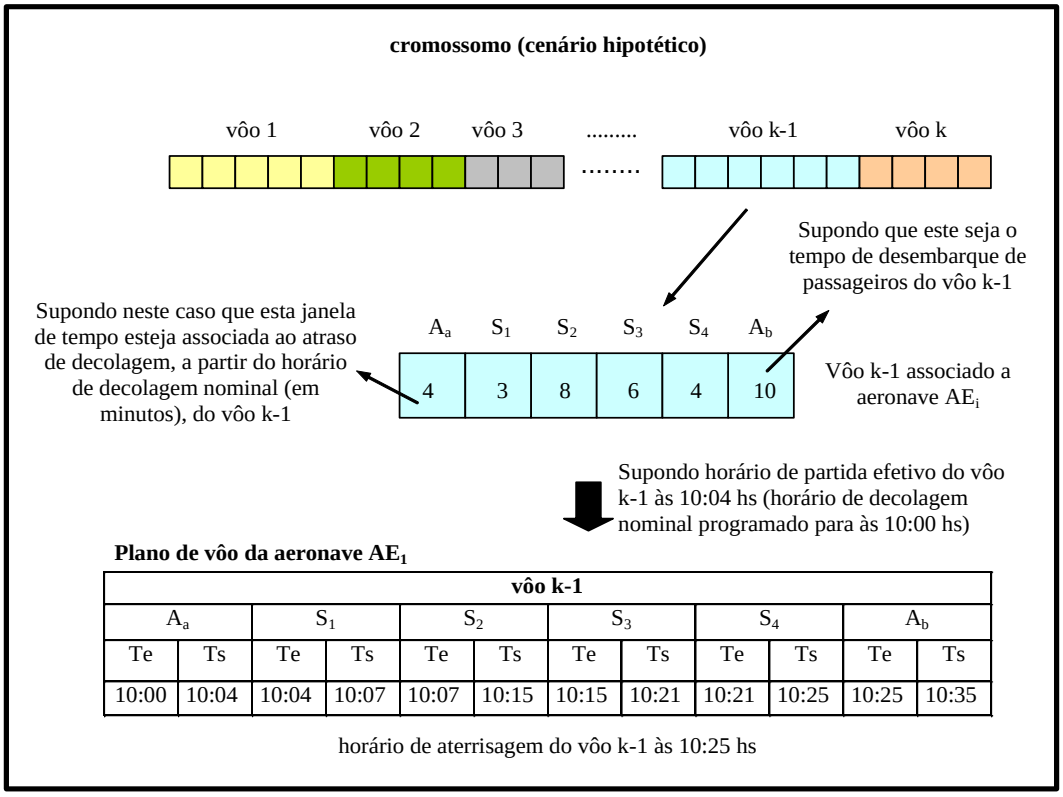

Figura 5.20: Plano de vôo real de uma aeronave dentro do cenário aeronáutico

O conjunto de todos os planos de vôo e aeronaves formam o cenário aeronáutico sugerido a ser executado no dia operacional dos vôos. Cada um destes cenários aeronáuticos otimizados, que podem ser considerados como sugestão de serem realizados na prática, é um cromossomo que compõem a população de cromossomos dos algoritmos genéticos. A população de cromossomos é composta por um conjunto de sugestões de cenários aeronáuticos que podem ser aplicados no dia efetivo dos vôos.

5.2.6 Fluxograma do Modelo de Otimização de Demanda Proposto

Neste item é apresentado uma visão geral da seqüência de passos executados pelo modelo de otimização proposto.

Na figura 5.21 são apresentados os passos para a otimização da demanda em cada setor e aeroporto dos diversos cenários aeronáuticos (cromossomos da população), durante o período de tempo em análise.

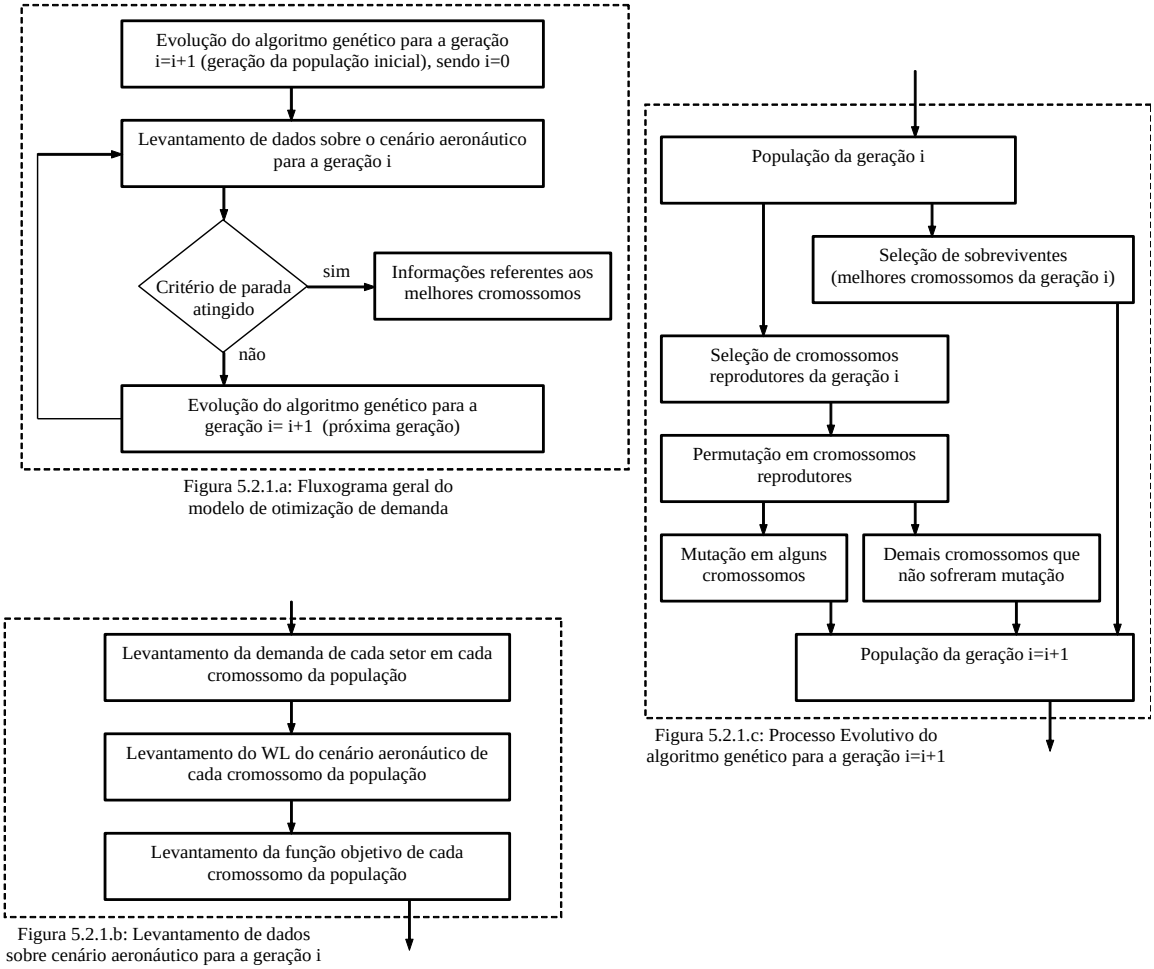

Figura 5.21: Fluxograma do modelo de otimização de demanda

O fluxograma incorpora tanto informações relativas ao cenário aeronáutico (levantamento da demanda e carga de trabalho de gerenciamento em setores), quanto à aplicação dos algoritmos genéticos. No item 5.3 são apresentados em maiores detalhes a aplicação de cada um dos algoritmos genéticos adotados nesta pesquisa.

Ao final do processo evolutivo dos algoritmos genéticos, para os melhores cromossomos obtidos, são fornecidas informações referentes:

- Demanda instantânea para todo o período de tempo analisado.
- Função objetivo.

- Carga de trabalho de gerenciamento global e em cada setor do cenário analisado.
- Atraso global e em cada setor e aeroporto do cenário aeronáutico analisado.
- Função objetivo auxiliar (custo hipotético de permanência em vôo).

Assim, podem ser criados os diagramas de análise de situação de cada setor do cenário aeronáutico, durante o período de tempo analisado. Com os diagramas de análise de situação e demais informações sobre custos e atrasos, poderá ser selecionado o cenário mais adequado a ser implantado em um caso real.

5.3 Modelos de Algoritmos Genéticos Adotados

Observou-se um elevado número de opções, tanto para o método de seleção, permutação e mutação, quanto para parâmetros internos dos algoritmos genéticos, tais como, critérios de parada (término de evolução dos algoritmos genéticos), tamanho da população etc.

Foram selecionadas três variedades de algoritmos genéticos, que definem 3 opções possíveis de implementação do modelo de otimização de demanda. Duas das opções foram definidas pelo método de seleção, e a terceira pelo processo de evolução:

- **Método de seleção por roleta:** também denominado de seleção proporcional; este método foi selecionado por ser tradicional, proposto originalmente por John H. (HOLLAND, 1995), sendo a base em termos de comparação com outros métodos de seleção.
- **Método de seleção por torneio:** este método foi selecionado por ser um método que apresenta bons resultados em diversas aplicações e problemas de alta complexidade, tal como visto em (FREGNI, 1997).
- **Evolução por abelha rainha:** em testes preliminares verificou-se que a taxa de mutação foi um dos operadores de maior influência no processo de otimização. A abelha rainha é um processo de evolução normalmente utilizado em problemas de otimização com grande influência pelo operador genético mutação (JUNG, 2003). Assim, justificou-se a adição deste método de evolução para este trabalho de pesquisa.

5.3.1 Modelo Utilizando Algoritmos Genéticos Seqüenciais

Os algoritmos genéticos seqüenciais foram pesquisados de acordo com as três opções anteriormente apresentadas.

5.3.1.1 Método de Seleção por Roleta (*Roulette Wheel Selection*)

O método de seleção por roleta, também denominado por método de seleção proporcional (*fitness proporcional*), é o mais antigo método de seleção, proposto por John Holland segundo (FREGNI, 1997). Nele a probabilidade de seleção para reprodução é proporcional ao valor de aptidão de cada cromossomo.

Neste método, imagina-se uma roleta, sendo que o tamanho de cada fatia ou setor desta roleta é proporcional à saúde ou aptidão de cada cromossomo da população. Desta forma, cada cromossomo é mapeado em um setor da roleta. Assim, quanto maior a largura do setor da roleta que ele ocupa, maior será a probabilidade deste cromossomo ser selecionado.

A figura 5.22 apresenta a analogia comentada para o método de seleção por roleta.

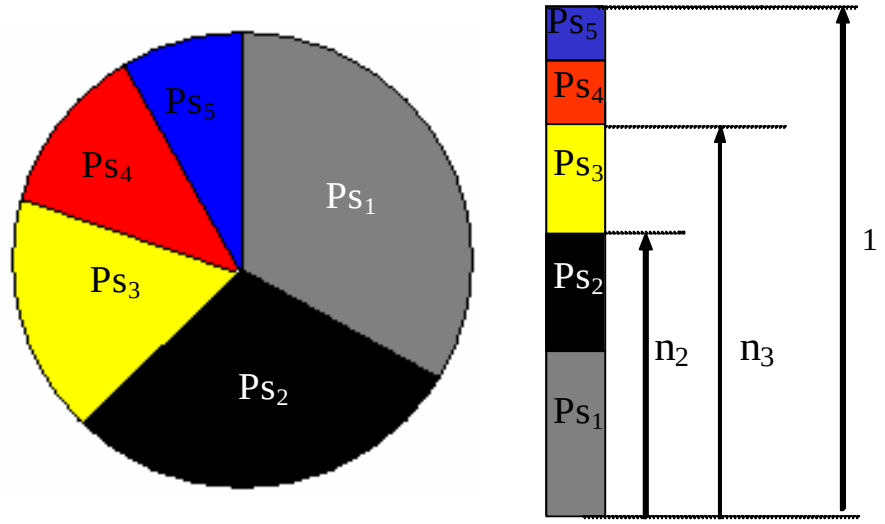

$n_2 < va < n_3 \Rightarrow$ cromossomo 3 é selecionado
va: variável aleatória entre 0 e 1

Figura 5.22: Método da roleta

Na figura Ps_i é a probabilidade de seleção do cromossomo i associado ao setor s_i da roleta. A seleção de cada cromossomo reprodutor corresponde a geração de uma variável

aleatória *va* entre 0 e 1. O cromossomo *i* selecionado será aquele que apresentar $n_{i-1}<va<n_i$, sendo n_i a "probabilidade acumulada" de seleção até o cromossomo *i* dada por:

$$n_i = \sum_{k=1}^{i} Ps_k \text{ (equação 18) e } \sum_{i=1}^{n} Ps_i = 1 \text{ (equação 19),}$$

sendo n o número total de cromossomos da população.

a) Geração da População Inicial

A população inicial de cromossomos é gerada de forma aleatória. Esta população é sempre mantida de tamanho constante, de geração a geração, durante todo o processo de evolução nos algoritmos genéticos. Adicionalmente, avalia-se a aptidão de cada cromossomo, através de sua função de aptidão.

b) Processo de seleção de reprodutores

O processo de seleção por roleta seleciona e realiza uma cópia dos cromossomos que poderão ou não participar do processo reprodutivo, de acordo com um outro fator denominado de taxa de reprodução (t_r), definido a priori.

Assim, utiliza-se uma variável aleatória reprodução (v_r). Se a taxa de reprodução for igual ou superior ao valor da variável aleatória reprodução, o cromossomo copiado é selecionado para o processo de reprodução. Neste caso, esta copia do cromossomo é transferida para uma estrutura em fila, denominado de fila de reprodutores. Caso contrário, a cópia do cromossomo é descartada para um depósito de descarte.

Esta fila é tipo FIFO (*First in, First Out*). Esta característica é importante, pois os cromossomos dentro desta estrutura já estão ordenados na seqüência de formação dos pares para a aplicação do operador permutação.

Um entre dois cromossomos selecionados seqüencialmente, formando um par para a aplicação do operador permutação, também é descartado, quando apresentam o mesmo fenótipo (mesma valor de aptidão). Este descarte ocorre, pois a reprodução entre dois cromossomos idênticos (incesto) não traz, a princípio, nenhum benefício às próximas gerações. Mostra-se que incestos, quando evitados, não trazem nenhum prejuízo ao processo de evolução e à diversidade genética da população (CRAIGHURST; MARTIN, 1995).

c) Processo de Reprodução

O processo de reprodução se aplica aos cromossomos reprodutores da seguida forma:

c.1) Permutação

Os cromossomos são pareados dois a dois, na mesma ordem que são retirados da fila de reprodutores. A estes pares é aplicada o operador permutação. O ponto de aplicação do operador permutação nos pares de cromossomos formados, será determinado de forma aleatória, devendo ser selecionado o mesmo ponto (*locus*) de ambos os cromossomos do par formado.

c2) Mutação

Após a ocorrência da permutação nos cromossomos ascendentes, poderá ocorrer a mutação. Para a decisão da aplicação ou não do operador mutação, utiliza-se um fator denominado de taxa de mutação (t_m), determinado a priori. Adicionalmente, utiliza-se uma variável aleatória mutação (v_m). Se a taxa de mutação for igual ou superior ao valor da variável aleatória mutação, o cromossomo descendente, gerado pela permutação, sofrerá mutação. Caso contrário, o cromossomo não sofrerá mutação e será transferido diretamente para uma população denominada de intermediária. Esta população intermediária é a população inicial da próxima geração, iniciando-se novamente a reprodução, ou seja, o processo evolutivo.

Nos cromossomos em que ocorrerá a mutação, o ponto de mutação é selecionado aleatoriamente.

d) População Intermediária

A população intermediária é a população da próxima geração, dentro do processo evolutivo, sendo formada por três tipos de cromossomos:

d.1) Cromossomos sobreviventes: são selecionados x%, à priori, dos melhores cromossomos, copiando-os diretamente para a população intermediária. Os sobreviventes passarão para a próxima geração, sem passar pelo processo de reprodução. Estes cromossomos, em conjunto com os cromossomos gerados pelo processo reprodutivo, irão compor a população da próxima geração. Os sobreviventes são importantes pois garantem a evolução da população, geração a geração. Os sobreviventes impõem que, na próxima geração, o melhor cromossomo seja no mínimo

igual ao da geração anterior. Desta forma, evita-se a ocorrência de um processo de involução, ou seja, de oscilações da aptidão dos melhores cromossomos da população, entre gerações consecutivas.

d.2) Cromossomos descendentes por permutação: cromossomos gerados apenas pelo operador permutação.

d.3) Cromossomos descendentes por permutação e mutação: cromossomos gerados pelos operadores permutação e mutação.

Observe que a roleta deve ser executada um número de vezes suficiente de forma a serem selecionados o equivalente a (1-x%) cromossomos reprodutores em cada geração, dado que o tamanho populacional é constante de geração à geração nos algoritmos genéticos.

Na população intermediária é realizada uma hierarquia (ordenação crescente) entre todos os cromossomos, de acordo com aptidão (função objetivo) de cada cromossomo. Esta população é a população da próxima geração, na qual reinicia-se o processo evolutivo.

e) Repetição do Processo

A evolução dos algoritmos genéticos ocorrem através da repetição dos itens de **b** a **d**, enquanto o critério de parada não for atingido. Existem diversos tipos de critérios de parada que podem ser adotados (FREGNI, 1997). Para a presente pesquisa o critério de parada preferencial é por estabilidade, ou seja, o da existência de *n* melhores organismos não modificados por *m* gerações, sendo *n* e *m* definidos a priori.

Neste critério de parada existe a probabilidade do processo de otimização alcançar o melhor, ou então, um bom nível de otimização, com menor consumo de recursos computacionais, quando comparado a outros critérios como, por exemplo, o critério de parada por número de gerações. Neste último, os algoritmos genéticos evoluem até atingir *m* gerações, sendo *m* definido a priori. No critério de parada por número de gerações, não se pode garantir que a otimização encontre a melhor solução em *m* gerações. Em contrapartida, dependendo do valor de *m* pode-se até atingir a convergência da solução muito antes de *m* gerações. Assim, o tempo de processamento entre a geração de estabilidade e atingir-se *m* gerações, poderá ser considerado como

desperdiçado. A figura 5.23 apresenta a aplicação do algoritmo genético utilizando o método de seleção por roleta.

Método de Seleção por Roleta (*Routette Wheel Selection)*

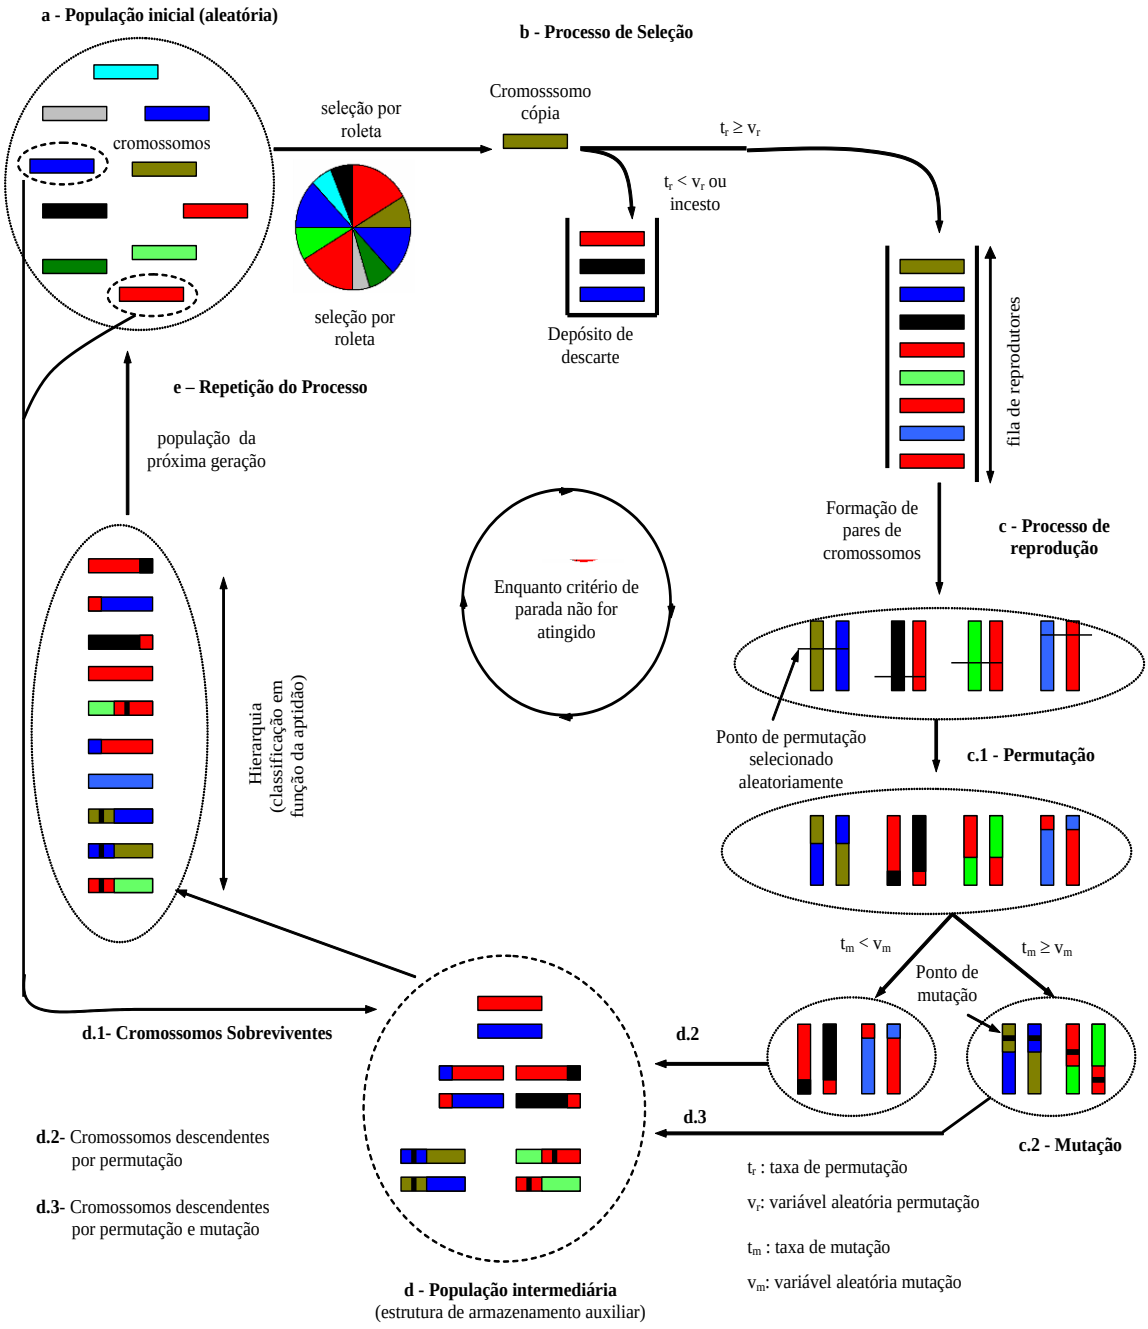

Figura 5.23: Método de Seleção por Roleta

5.3.1.2 Método de Seleção por Torneio *q* (*q Tournoment Selection*)

No método de seleção por torneio para cada cromossomo selecionado para reprodução, deve-se anteriormente criar uma população de torneio *q*, ou seja, uma população de tamanho igual a *q* cromossomos. Estes *q* cromossomos podem ser selecionados por algum outro método de seleção, mas deve ser de forma equiprovável (HOLLAND, 2000). Aqui está sendo adotado o método de seleção por roleta para a criação da população de torneio *q*, devido a sua simplicidade, com tamanhos iguais de cada setor da roleta. Dentre os *q* cromossomos da população torneio *q*, será selecionado o de melhor aptidão para a reprodução.

A roleta equiprovável deve ser executada um número de vezes suficiente de forma a serem criadas o equivalente a (1-x%) populações de torneio q, sendo x% o número equivalente de cromossomos sobreviventes.

Estudos realizados por Tobias Blickle e Lothar Thiele do Instituto Federal de Tecnologia de Zurique, através de modelos matemáticos e simulações, mostram que, dentre todos os métodos de seleção com a mesma pressão seletiva, a seleção por torneio apresenta a menor perda de diversidade genética (FREGNI, 1997). Esta característica pode ser interessante para o modelo de otimização de demanda em infra-estrutura aeronáutica proposto.

Assim, para o método de seleção por torneio todos os cromossomos *i* da população apresentam a mesma probabilidade de seleção Ps_i, para compor a população de torneio *q* em cada geração, conforme descrito a seguir.

$$Ps_i = \frac{1}{n} \quad \text{(equação 20)}$$

sendo n o número de setores (cromossomos) da roleta equiprovável.

A figura 5.24 apresenta a aplicação do algoritmo genético utilizando o método de seleção por torneio.

Método de Seleção por Torneio *q* (*q Tournoment Selection)*

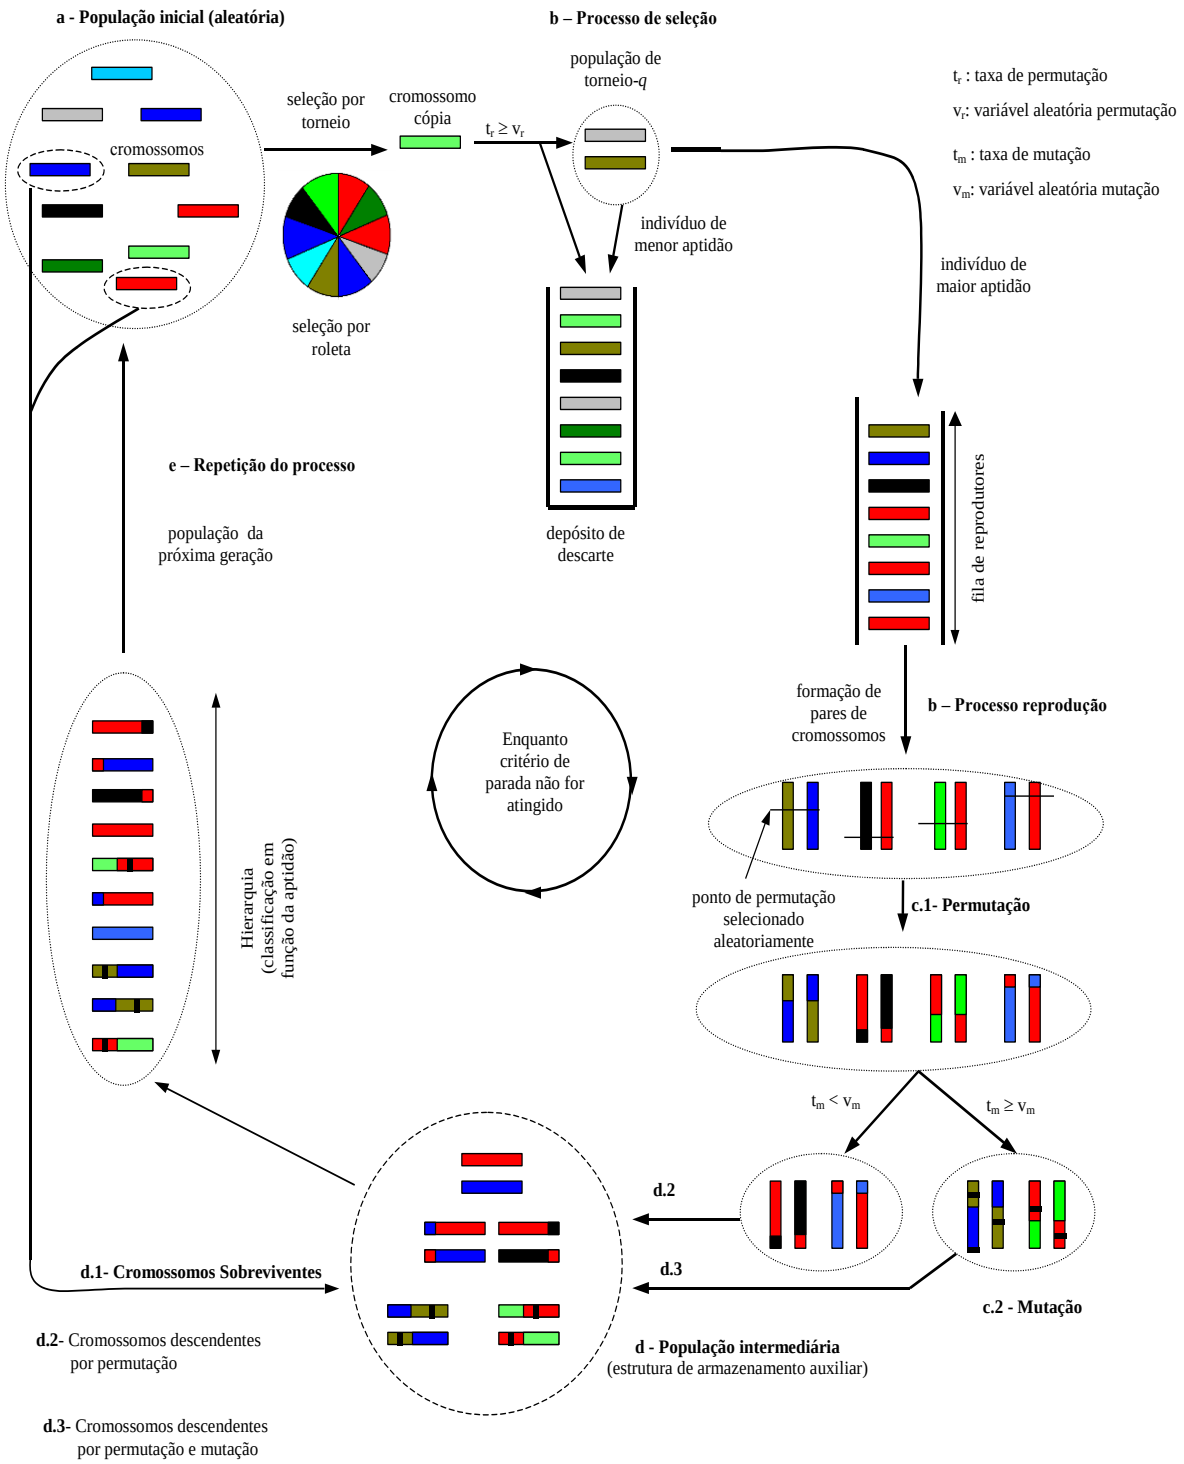

Figura 5.24: Método de Seleção por Torneio

5.3.1.3 Evolução por Abelha Rainha (*Queen Bee Evolution*)

Os algoritmos genéticos imitam a natureza em seu processo de evolução. Em alguns processos de evolução mais particulares, um indivíduo especial cruza (permuta) com outros indivíduos reprodutores da população. Este indivíduo se apresenta como especial, seja pela capacidade de atrair outros indivíduos, seja pela força física, ou por outras características que o tornem especial em relação à reprodução, conforme ocorre na maioria dos insetos.

No caso do método de evolução por abelha rainha (comunidade de abelhas), a abelha rainha é responsável pela reprodução. A abelha rainha é o cromossomo com maior aptidão em cada geração, cruzando com todos os zangões, ou seja, os demais reprodutores da população, também selecionados em cada geração. Os zangões são selecionados por algum método de seleção (JUNG, 2003). Neste trabalho de pesquisa foi adotado o método de seleção por roleta para os demais reprodutores, também devido a sua simplicidade.

Existem diferenças entre algoritmo genético utilizando a evolução por abelha rainha e os dois algoritmos genéticos anteriormente apresentados. Estas diferenças basicamente estão relacionadas ao processo de reprodução, destacando-se:

- Permutação: o operador permutação ocorre de forma diferente, em relação à permutação anteriormente apresentada, em que são selecionados n cromossomos reprodutores, formando $n/2$ pares nos quais serão aplicados o operador permutação. Na abelha rainha também são formados $n/2$ pares de cromossomos em cada geração, mas neste caso são selecionados $(n/2)+1$ cromossomos reprodutores, sendo $n/2$ o número de zangões reprodutores, selecionados pelo método de seleção por roleta, e uma abelha rainha, que corresponde ao cromossomo de melhor aptidão. A permutação é realizada entre a abelha rainha e os zangões reprodutores, sendo o ponto de cruzamento em cada um dos $n/2$ pares formados, selecionado aleatoriamente.
- Mutação: a mutação apresenta como diferenças a utilização dos parâmetros taxa de mutação normal (ε), probabilidade de mutação normal (p_{mn}), e probabilidade de supermutação (p_{sm}). A mutação ocorre de duas formas: a primeira através da

probabilidade de mutação normal, na qual ocorrem mutações com pequena probabilidade de ocorrência; a segunda através da probabilidade de supermutação, na qual ocorrem mutações com grande probabilidade de ocorrência.

A taxa de mutação é utilizada para dividir os reprodutores em dois segmentos. No primeiro segmento, ε dos novos cromossomos descendentes, obtidos pela permutação, poderão sofrer mutações com probabilidade de mutações normal (p_{mn}). No segundo segmento ($1-\varepsilon$) cromossomos descendentes poderão também sofrer mutação, mas agora com probabilidade de supermutação (p_{sm}).

Em ambos os casos, os pontos de mutação (gene), tanto para probabilidade de mutação normal quanto de supermutação, ocorrem normalmente em um único ponto (JUNG, 2003).

Para a decisão da aplicação ou não da mutação normal, a probabilidade de mutação normal (p_{mn}) é determinada a priori. Adicionalmente, utiliza-se uma variável aleatória de mutação normal (v_{mn}). Se a probabilidade de mutação normal for igual ou superior ao valor da variável aleatória mutação normal, o cromossomo descendente, gerado pela permutação e selecionado para a mutação normal, sofrerá mutação.

Igualmente, para a decisão da aplicação ou não da supermutação, a probabilidade de supermutação (p_{sm}) é determinada a priori. Também é utiliza uma variável aleatória de supermutação (v_{sm}). Se a probabilidade de supermutação for igual ou superior ao valor da variável aleatória de supermutação, o cromossomo descendente, gerado pela permutação e selecionado para a supermutação, também sofrerá mutação.

A figura 5.25 apresenta a aplicação do algoritmo genético utilizando o método de evolução por abelha rainha.

A adoção de permutação entre o melhor cromossomo de cada geração (abelha rainha) com os demais cromossomos reprodutores (zangões) aumenta a capacidade de exploração dos algoritmos genéticos. Em contra partida, aumenta-se também a possibilidade de ocorrer convergências prematuras (máximos locais) (JUNG, 2003), com resultados de otimização abaixo dos melhores resultados que poderiam ser alcançados. A aplicação da supermutação procura resolver este problema de forma a evitar essa ocorrência. O objetivo neste caso é aumentar a capacidade de exploração dos algoritmos

genéticos através da exploração de novos pontos do espaço de pesquisa que possam permitir sair deste máximo local.

Evolução por Abelha Rainha *(Queen Bee Evolution)*

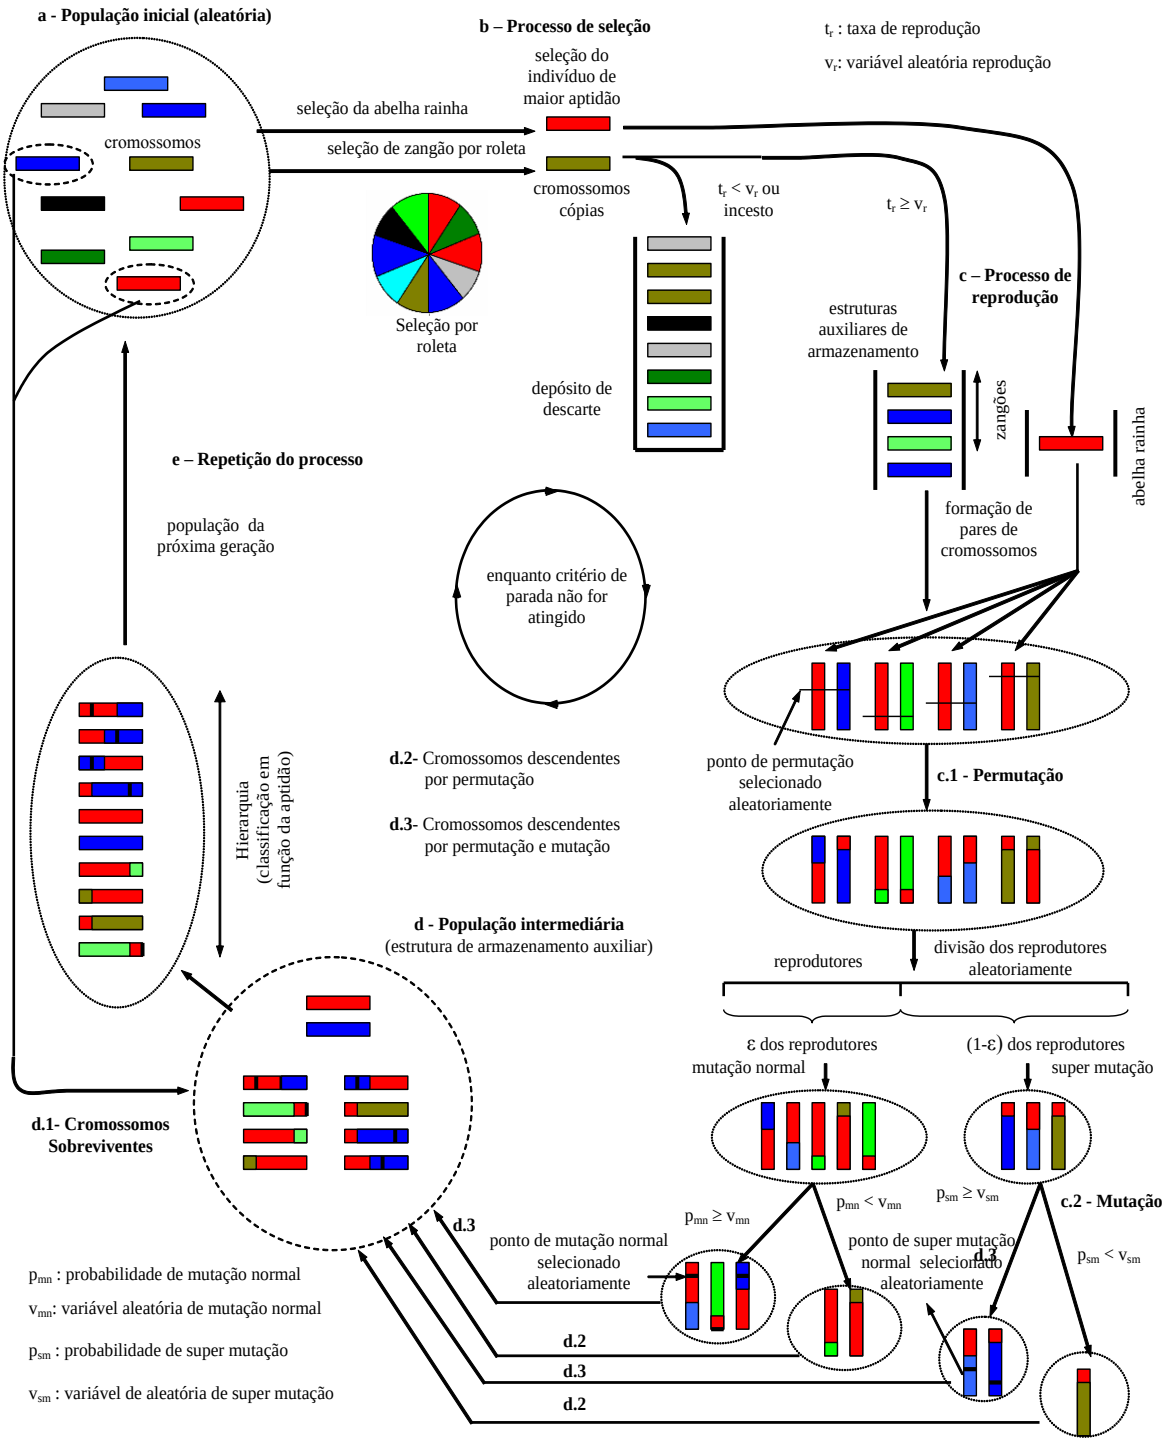

Figura 5.25: Evolução por Abelha Rainha

Jung (JUNG, 2003) realizou testes com o método de evolução por abelha rainha e demonstrou que, para alguns problemas combinatórios, esse método apresentou bom desempenho.

5.3.2 Modelo Utilizando Algoritmos Genéticos Paralelos

Devido a grande diversidade de algoritmos genéticos paralelos já apresentados no capítulo 4, adotou-se, neste trabalho de pesquisa, o modelo de algoritmo genético paralelo em ponte devido a sua simplicidade de implementação, quando comparado a outros algoritmos genéticos paralelos (PAZ, 2000).

5.3.2.1 Modelo em Ponte

Neste modelo cada ilha possui duas ilhas vizinhas, sendo a comunicação de cada ilha restrita há apenas uma de suas ilhas vizinhas. A figura 5.26 apresenta a topologia implementada.

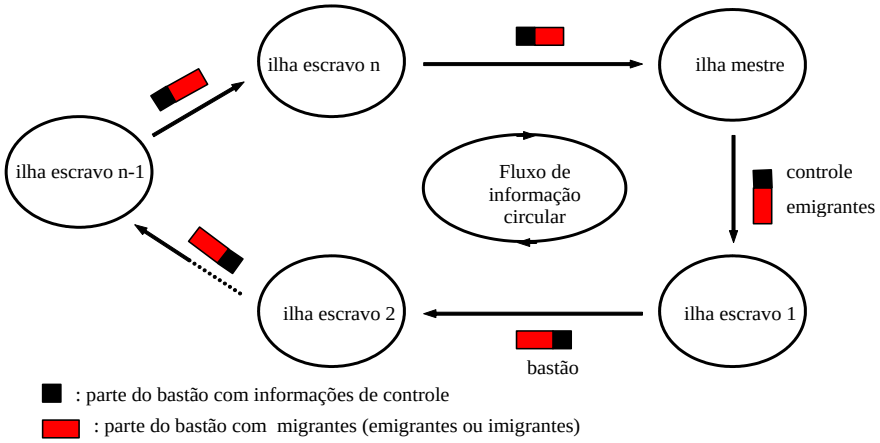

Figura 5.26: Modelo em Ponte

Cada ilha possui a sua subpopulação e seu respectivo algoritmo genético. Pela topologia apresentada observe que existe um fluxo de informação entre as ilhas que é realizado de forma circular. Este fluxo de informação, aqui denominado de bastão, possui algumas características descritas por (RAUBER; REILEIN; RÜNGER, 2001), que contém dois tipos de informações circulando entre as ilhas. Estas informações são:

- Migrantes: melhores cromossomos de uma ilha e seus respectivos valores de aptidão que são trocados entre duas ilhas vizinhas. O bastão pode ser enviado

(bastão com emigrantes) para uma ilha, ou então, pode ser recebido (bastão com imigrantes) da uma ilha vizinha.

- Controle: conjunto de informações utilizadas para controle de parada simultâneo de todas as ilhas, ou seja, controle de parada global. O controle apresenta o formato apresentado na figura 5.27:

finaliza	*escravo n*	*escravo n-1*	.....	*escravo 2*	*escravo 1*	*mestre*

Figura 5.27: Mapeamento dos campos de controle

Cada campo dentro da estrutura de controle pode assumir um entre dois valores:

- Campos *mestre* e *escravos* de *1* a *n*:

  Valor zero: ainda não atingiu o critério de parada local.

  Valor um: já se atingiu o critério de parada local.

- Campo *finaliza*:

  Valor zero: ainda não atingiu o critério de parada global.

  Valor um: atingiu-se o critério de parada global.

Cada ilha possui uma posição específica dentro da estrutura de controle, no qual somente ela pode alterar o valor nela contido. A figura 5.27 apresenta a posição referente a cada ilha escrava (campos *escravo 1* à *escravo n*) e a ilha mestre (campo *mestre*). Em sua posição específica, dentro da estrutura de controle, cada ilha (mestre e escravas) coloca o valor zero ou um, caso tenha sido atingido ou não o critério de parada a cada geração do seu algoritmo genético.

A cada *n* gerações, definidas a priori, é identificada a geração para o envio e recebimento do bastão entre as ilhas. Este critério de envio, somente após *n* gerações, foi adotado de forma a evitar que o excesso de comunicação entre ilhas interferisse de forma significativa no tempo de otimização do algoritmo genético paralelo.

No momento de envio e recebimento do bastão a ilha mestre consulta as posições dos campos de controle *escravo* de *1* a *n* e *mestre*. Caso todas estas posições apresentem valor igual a um, significa que foi atingido o critério de parada local em todas as ilhas. Neste instante é determinado o critério de parada global, em que a evolução do

algoritmo genético paralelo como um todo é alcançado. Assim, o campo de controle *finaliza* passa a ter o valor um.

Igualmente, a cada *n* gerações as ilhas escravas, no momento do envio e recebimento dos bastões com seus vizinhos, também consultam o campo *finaliza* para verificar se o critério global foi atingido.

Fato importante a ser observado é que se pelo menos uma das ilhas não atingir o seu critério de parada local, todas as ilhas devem continuar ainda tentando evoluir.

A comunicação entre ilhas para o envio de bastão é realizada através do MPI (*messege passing interface*), que utiliza o mecanismo de comunicação através de passagem de mensagem (*messege passing*). Através deste mecanismo as mensagens (informações) são trocadas de forma explícita, isto é, são passadas através de comandos (linguagem de programação) declarados explicitamente.

Cada ilha possui um espaço de memória específico (*buffer*) para recepção de mensagens. Desta forma, uma ilha envia um bastão diretamente para o buffer da sua ilha vizinha.

A ilha mestre, após *n* gerações, atualiza a sua condição de parada, através da sua posição dentro da estrutura de controle, e verifica se foi atingido o critério de parada global. Caso este não tenha sido atingido e o bastão tenha sido recebido de sua ilha vizinha, ele retira os imigrantes enviados por esta ilha, e insere os seus emigrantes no bastão, enviando-o a próxima ilha escrava. Todas as demais ilhas, até a última ilha escrava, que tem o mestre como vizinho, realizam o mesmo procedimento, e assim fecha-se o ciclo de comunicação ou de passagem do bastão.

A partir do fechamento do ciclo de passagem de bastão são realizadas *n* gerações em cada ilha e o ciclo de passagem de bastão novamente se inicia. Este ciclo se repete até que o critério de parada global seja atingido, finalizando então o processo evolutivo do algoritmo genético paralelo.

A figura 5.28 apresenta a seqüência de troca de mensagens entre ilhas, através do MPI dentro de um ciclo de passagem de bastão.

Observe que este ciclo de informações acaba se tornando um mecanismo de sincronismo dentro do algoritmo genético paralelo, ditando o ritmo de execução do mesmo. Este mecanismo de sincronismo facilita a implementação e controle do algoritmo genético

paralelo. Um provável problema desta topologia é se uma das ilhas apresentar processamento mais lento. Esta ilha irá ditar o ritmo ou velocidade de execução do algoritmo genético paralelo como um todo. Neste caso, para obter um melhor desempenho em termos velocidade de processamento, é interessante que todas as ilhas apresentem as mesmas características de desempenho. Problema semelhante também pode ocorrer se os algoritmos genéticos em cada ilha forem de tipos ou características diferentes, por exemplo, apresentarem métodos de seleção e tamanhos populacionais diferentes, fazendo com que o tempo de execução de n gerações em cada ilha seja significativamente diferente.

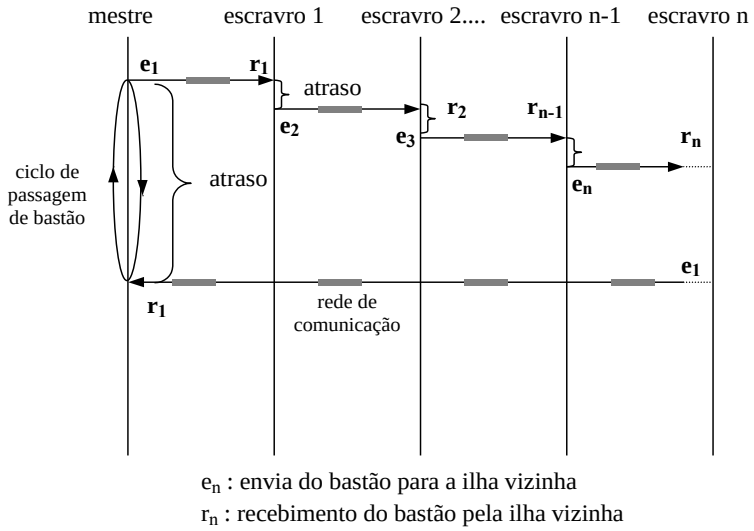

Figura 5.28: Mensagens trocadas entre ilhas

Observe na figura 5.28 que existe um atraso entre o recebimento e envio do bastão em uma mesma ilha. Este atraso é função do tempo de processamento em cada ilha para atingir n gerações. Quanto maior for a diferença de tempos de processamento entre as ilhas, maior será este atraso. Note que para a ilha mestre, o atraso desta será a somatória dos atrasos de todas as ilhas, mais o atraso gerado por ela própria.

Qualquer uma das ilhas, mestre ou escrava, poderá utilizar um dos algoritmos genéticos seqüenciais apresentados. Para tanto, estes algoritmos genéticos necessitam de alterações com o objetivo de permitir incorporar os cromossomos imigrantes às suas populações, bem como enviar cromossomos emigrantes a cada n gerações.

A figura 5.29 apresenta um exemplo de algoritmo genético seqüencial em uma ilha do algoritmo genético paralelo em ponte.

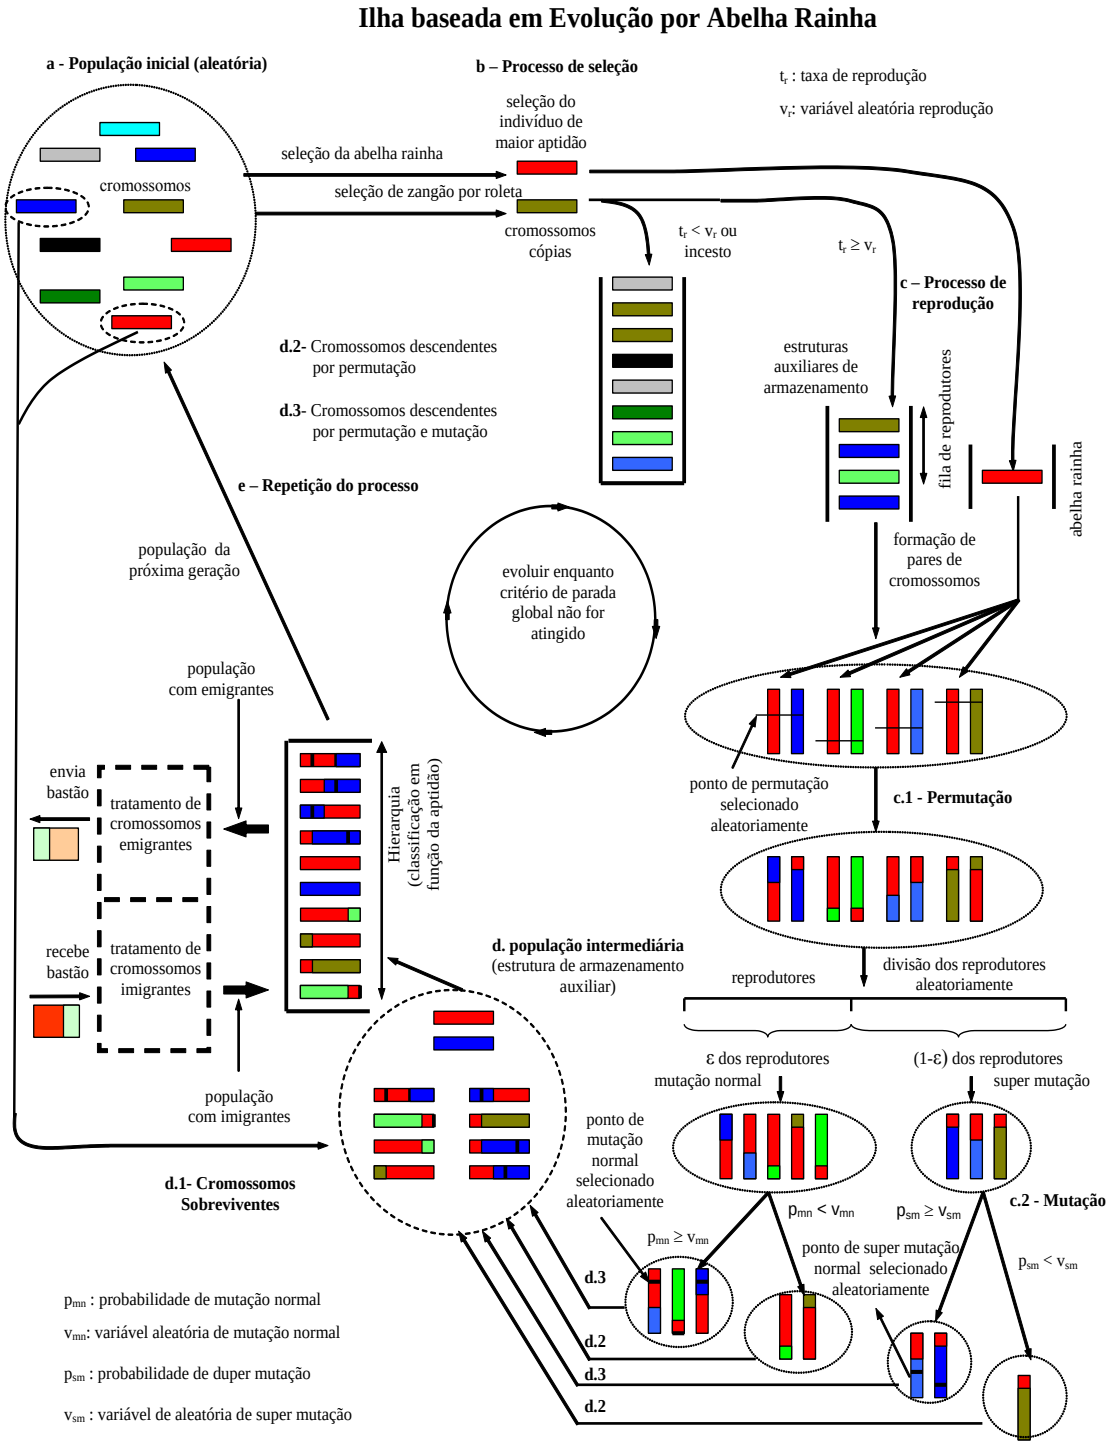

Figura 5.29: Ilha baseada em Evolução por Abelha Rainha

A figura refere-se a uma ilha contendo o algoritmo genético evolução por abelha rainha. As alterações são idênticas para os demais algoritmos genéticos seqüenciais estudados, seja uma ilha mestre ou escrava.

5.3.2.2 Tratamento de Migrantes

O tratamento de cromossomos migrantes torna os algoritmos genéticos seqüenciais em cada ilha aptos a receber (imigrantes) e enviar (emigrantes) cromossomos. A figura 5.30 apresenta o tratamento dos emigrantes e imigrantes.

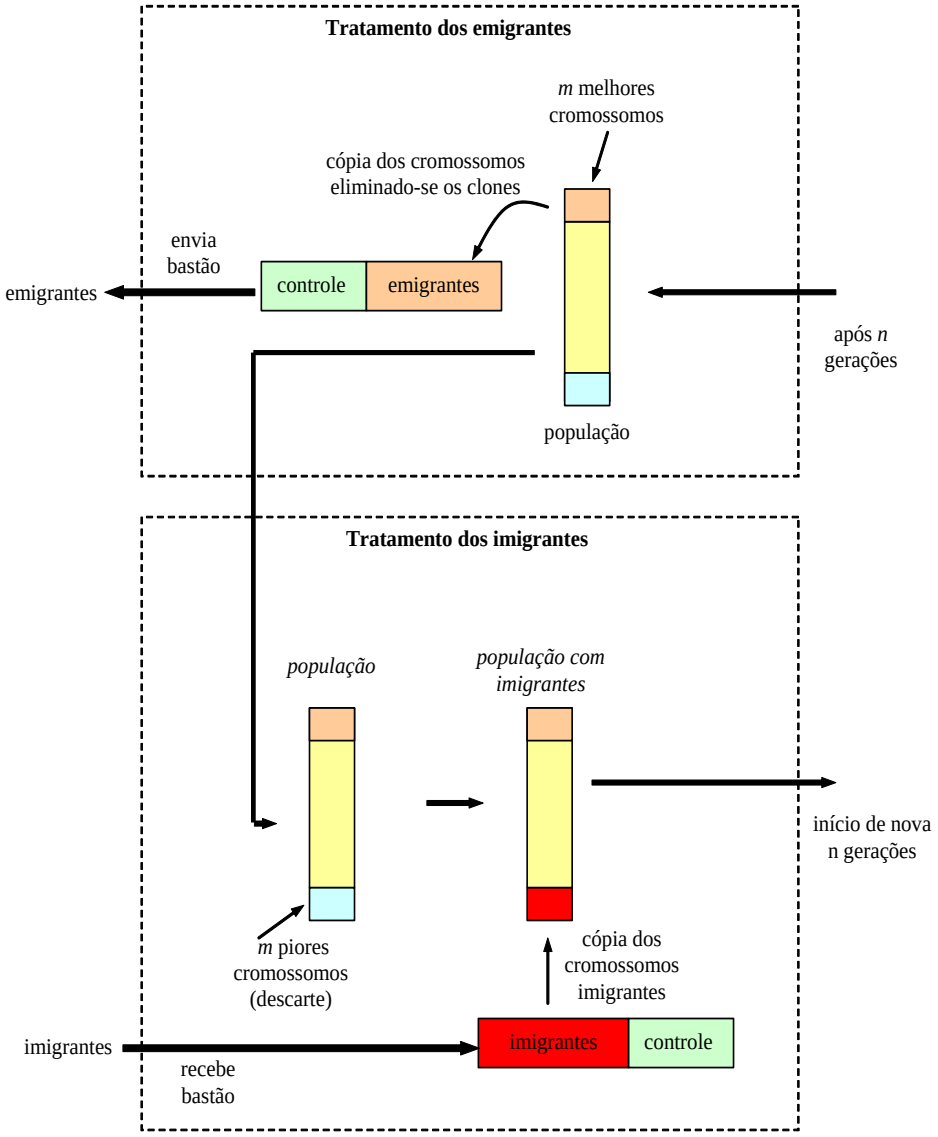

Figura 5.30: Tratamento dos emigrantes e imigrantes no alg. genético paralelo em Ponte

a) Tratamento dos emigrantes

Após a realização de *n* gerações pela ilha, os *m* melhores cromossomos de sua subpopulação são inseridos no bastão e, enviados a sua ilha vizinha.

Na seleção dos emigrantes também é evitado a existência de clones, ou seja, a não existência de dois cromossomos emigrantes com o mesmo valor de função objetivo. O objetivo desta medida é aumentar ainda mais a diversidade genética durante o processo de evolução, entre as diversas ilhas do algoritmo genético paralelo.

b) Tratamento dos imigrantes

Após o tratamento dos emigrantes os *m* piores cromossomos são eliminados da subpopulação da ilha, sendo substituídos pelos *m* melhores cromossomos imigrantes da ilha vizinha, recebidos pelo bastão. Desta forma, o tamanho populacional original é recomposto novamente.

Após o tratamento de emigrantes e imigrantes, é realizada uma nova classificação da subpopulação (hierarquia) da ilha, devido à inserção dos imigrantes na subpopulação. A partir deste momento, inicializa-se novamente o processo de evolução de *n* gerações do algoritmo genético da ilha, ocorrendo novamente o tratamento dos emigrantes e imigrantes. O processo continua até que o critério de parada global seja atingido.

No próximo capítulo é apresentado um estudo de caso dentro do contexto brasileiro, no qual é utilizado o modelo de otimização de demanda proposto em infra-estrutura aeronáutica, através de três algoritmos genéticos seqüenciais e um algoritmo genético paralelo.

Neste capítulo é apresentado o estudo de caso para o contexto aeronáutico brasileiro. Para tanto, é considerado um cenário aeronáutico que compreende as cidades de Brasília, Belo Horizonte, Rio de Janeiro e São Paulo. Este cenário aeronáutico foi selecionado por ser considerado de alta criticidade, dentro do cenário aeronáutico brasileiro.

6 MODELO DE OTIMIZAÇÃO DE DEMANDA EM INFRA-ESTRUTURA AERONÁUTICA APLICADO AO CONTEXTO BRASILEIRO

"As ciências são divididas em dois grandes grupos de acordo com seu conteúdo: formais e factuais. A lógica e a matemática integram as ciências formais, são objetos abstratos cujos argumentos e teoremas dispensam testes para a sua comprovação. As ciências factuais, também chamadas de experimentais ou empíricas, tratam de objetos que dependem de testes para comprovar experimentalmente suas hipóteses, estão inseridos nos demais campos do conhecimento."

O método científico,
Fernando Gewamdsznajder, Pioneira, São Paulo, 1989

Este capítulo apresenta um estudo de caso real dentro do contexto aeronáutico brasileiro considerado o cenário de maior criticidade[1] em termos de volume de tráfego brasileiro. Este cenário aeronáutico engloba as regiões de Belo Horizonte, Brasília, Rio de Janeiro e São Paulo.

6.1 Infra-estrutura Aérea Simulada

A infra-estrutura aérea simulada é apresentada na figura 6.1, obtida em conjunto com o Centro de Gerenciamento de Tráfego Aéreo (CGNA) após algumas reuniões e discussões.

[1] Centro Tecnológico da Aeronáutica, Centro de Gerenciamento e Navegação Aérea, **Reunião de estudo**, São José dos Campos, em 15 março de 2003. Comunicação Verbal através de especialistas em tráfego aéreo.

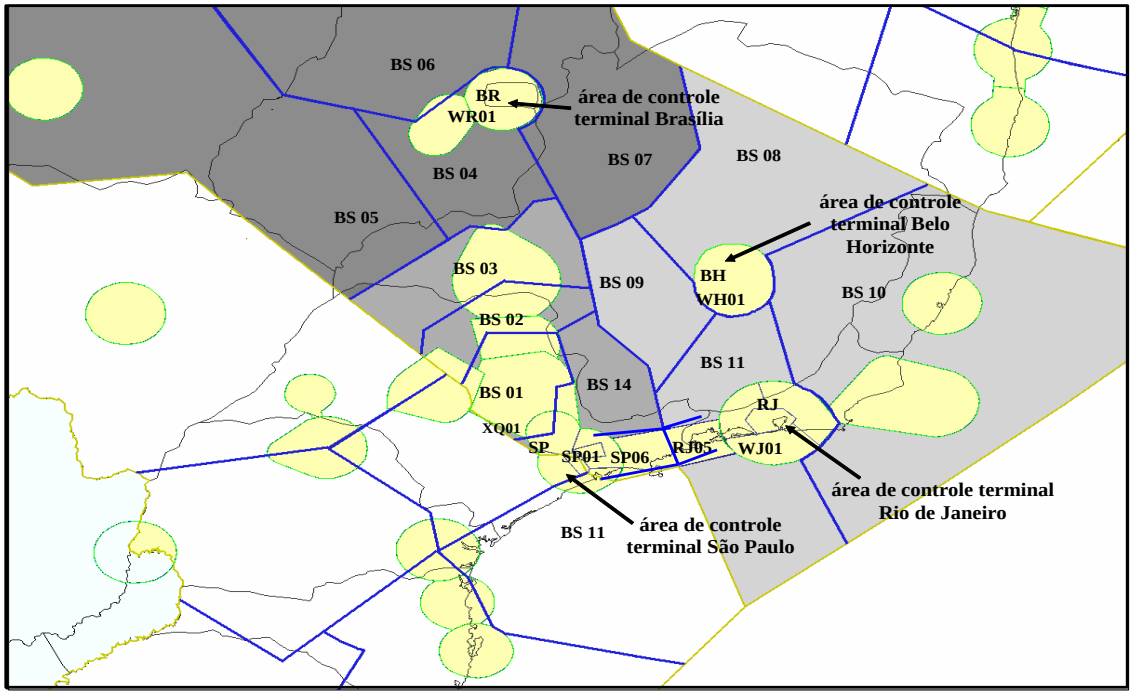

Figura 6.1: Infra-estrutura aérea estudada

A infra-estrutura aérea apresentada possui os seguintes elementos:

- Áreas de Controle Terminais: setores WH01, WR01, WJO1, SP01 (XP01 à XP05) e XQ01 que correspondem respectivamente a Belo Horizonte, Brasília, Rio de Janeiro e São Paulo.
- Espaço Aéreo Superior: setores BS01, BS02, BS03, BS04, BS07, BS08, BS09, BS11 e BS14. Os setores RJ05 e SP06 também estão no espaço aéreo superior, sendo utilizados pela ponte aérea entre Rio de Janeiro e São Paulo.

A tabela 6.1 apresenta as capacidades nominais declaradas de todos os setores do cenário aeronáutico estudado, sejam eles de Áreas de Controle Terminal, sejam do Espaço Aéreo Superior.

Adicionalmente, também é apresentado o número de aeronaves que ocupam cada um dos setores do cenário aeronáutico durante o período de tempo analisado, bem como a qual Área de Controle Aéreo pertence cada um dos setores (ACC ou APP). Todos estes dados foram fornecidos pelo Centro de Gerenciamento de Tráfego Aéreo (CGNA).

Setor	Capacidade nominal declarada	N° aeronaves por setor durante o período de análise	Área de controle aéreo
WJ01	32	496	APP
WH01	12	220	APP
WR01	20	333	APP
XP01	7	633	APP
XP02	7	295	APP
XP03	7	478	APP
XP04	4	179	APP
XP05	4	306	APP
RJ05	12	299	ACC
SP06	12	295	ACC
BS01	14	223	ACC
BS02	14	211	ACC
BS03	14	182	ACC
BS04	14	173	ACC
BS07	14	184	ACC
BS08	14	165	ACC
BS09	14	253	ACC
BS11	14	162	ACC
BS14	14	272	ACC
XQ01	10	4	ACC

Tabela 6.1: Informações sobre o cenário aeronáutico estudado

Os aeroportos envolvidos no cenário aeronáutico em estudo e que apresentam Planos de Vôo Repetitivo (RPL) são respectivamente (INFRAERO, 2004):

Brasília: aeroporto internacional de Brasília.

Belo Horizonte: aeroporto de Belo Horizonte (Pampulha), aeroporto internacional Tancredo Neves (Confis) e aeroporto Carlos Prates.

Rio de Janeiro: aeroporto internacional do Rio de Janeiro/Galeão e aeroporto Santos Dumont.

São Paulo: aeroporto internacional de São Paulo/Guarulhos, aeroporto internacional de Viracopos/Campinas , aeroporto internacional de São Paulo/Congonhas.

6.2 Parâmetros Externos ao Modelo

Os parâmetros externos ao modelo referem-se aos dados que definem o cenário aeronáutico a ser analisado.

- Cenário aeronáutico

  Os dados de entrada do modelo de otimização são referentes ao dia 06/05/2003 (24 horas) obtidos junto ao Centro de Gerenciamento de Tráfego Aéreo (CGNA) e apresentam as seguintes características:

  - Compreendem os aeroportos dentro das Aéreas de Controle Terminal de Belo Horizonte, Brasília, Rio de Janeiro e São Paulo, bem como os Espaços Aéreos Superiores que compreendem as rotas que interligam estes aeroportos.
  - Os dados fornecidos são referentes a um total de 1654 vôos distribuídos pelas diversas rotas que definem o cenário aeronáutico em estudo.
  - Todas as rotas foram consideradas como diretas, dado que não foram fornecidas informações que pudessem identificar quais vôos estavam em escala. Esta hipótese não trouxe prejuízo ao estudo de caso realizado.
  - Os tempos médios de permanência nominal (padrão) das aeronaves nos setores foram determinados para cada um dos 1654 vôos. Estes tempos de permanência nominal foram deduzidos a partir de dados fornecidos pelo CGNA. Esta sendo adotado que os tempos médios de permanência nominal são constantes e iguais para um mesmo tipo de aeronave, em cada um dos setores da infra-estrutura aeronáutica.
  - O cenário aeronáutico analisado é composto por 20 setores, sendo 8 setores de Área de Controle Terminal (associados a APPs) e 12 setores do Espaço Aéreo Superior (associados a ACCs).
  - Em função do número de setores e vôos realizados para o cenário aeronáutico e período de tempo em análise, cada cromossomo obtido, que corresponde a uma solução para o problema de otimização, apresenta 7017 genes.

- Tempo de análise

  Refere-se ao tempo de análise (simulação) em que será realizada a otimização. No estudo de caso foi considerado um tempo de análise de 24 horas.

- Instante inicial de simulação.

- A simulação considera que no instante zero já existem algumas aeronaves em vôo dentro do cenário aeronáutico analisado, e que devem ser consideradas para garantir maior realismo na análise realizada.

6.3 Parâmetros Internos ao Modelo

Os parâmetros internos ao modelo são aqueles referentes à definição de estados de demanda e janelas de tempos, referentes ao cenário aeronáutico analisado. Os parâmetros aqui apresentados foram definidos conforme a seguir[1 e 2] :

- Condição de demanda

  Em função do apresentado no Capítulo 5, foram adotados 5 estados de demanda:

  - **Setor normal:** quando a demanda está abaixo de 80% da capacidade normal do setor.
  - **Setor congestionado:** quando a demanda está entre 80% e 100% da capacidade nominal declarada do setor.
  - **Setor saturado aceitável:** quando a demanda está entre 100% e 120% da capacidade nominal declarada do setor.
  - **Setor supersaturado:** quando a demanda está acima de 120% da capacidade nominal declarada do setor.

  Enquanto a demanda em cada setor for igual ou inferior a 80% de sua capacidade nominal declarada, o setor não será considerado em estado de demanda excessiva, e a carga de trabalho (WL) do controlador de tráfego aéreo será igual a 1, conforme já apresentado no Capítulo 5.

- Janelas de tempo em setores

  - Setores do Espaço Aéreo Superior: janela inicia-se desde 5% a menos até 5% a mais do tempo médio nominal em cada setor. Apresenta uma maior flexibilidade em relação aos setores de Área de Controle Terminal, por serem menos restritivos.

[1] Centro Tecnológico da Aeronáutica, Centro de Gerenciamento e Navegação Aérea, **Reunião de estudo**, São José dos Campos, em 15 março de 2003. Comunicação Verbal através de especialistas em tráfego aéreo.
[2] SIEWERDT E., **Reunião sobre a pesquisa**, Escola Politécnica da Universidade de São Paulo, São Paulo, 10 junho 2003, (informações verbais).

- Áreas de Controle Terminais: janela inicia-se desde 3% a menos até 5% a mais do tempo médio nominal da Área de Controle Terminal. A adoção desta janela refere-se ao fato de que em setores das Áreas de Controle Terminais, devido à proximidade dos aeroportos destino e do momento de aterrisagem, as desacelerações adicionais são mais freqüentes que as acelerações adicionais das aeronaves.

- Janelas de tempo em aeroportos
  - Aeroportos em SP e RJ: janela de tempo estão associadas apenas aos atrasos em relação ao horário de decolagem nominal dos vôos, e termina em até 5 minutos depois do horário de decolagem nominal (entrada da aeronave em sua Área de Controle Terminal). Nestes aeroportos é considerado janelas de menor tamanho, devido ao elevado número de vôos e congestionamentos. As janelas de tempo maiores nesses aeroportos podem gerar atrasos elevados, comprometendo a qualidade dos serviços de transporte aéreo realizados.
  - Aeroportos em BH e BR: janela termina até 15 minutos depois do horário de decolagem nominal (entrada da aeronave na Área de Controle Terminal).
- Janelas de tempo de entrada no cenário aeronáutico
  - Os vôos podem entrar desde 15 minutos antes até 15 minutos depois do horário nominal definido para entrada de cada aeronave no setor do Espaço Aéreo Superior.

Nos aeroportos foram consideradas apenas janelas de tempo associadas a atrasos de decolagem das aeronaves, pois não foi possível obter a logística de ocupação das aeronaves nestes aeroportos que compõem o cenário aeronáutico estudado. O dimensionamento de capacidade e carga de trabalho em aeroportos é bastante complexo e merece pesquisas específicas, que podem ser futuramente incoporados ao modelo de otimização proposto.

Adicionalmente, foram levantadas as curvas de estimativa de carga de trabalho para os diferentes tamanhos dos setores no cenário aeronáutico estudado. O Apêndice B - Curvas de Carga de Trabalho de Gerenciamento apresenta todas as curvas levantadas e o método de estimativa dos mesmos.

6.4 Ambientes Computacionais de Simulação

Os ambientes computacionais utilizados neste trabalho de pesquisa pertencem aos seguintes laboratórios:

a) Laboratório de Arquitetura e Software Básico

O Laboratório de Arquitetura e Software Básico - LASB do Departamento de Engenharia da Computação e Sistemas Digitais da Escola Politécnica da USP realiza pesquisas e projetos relacionados com as áreas de processamento paralelo e distribuído. O ambiente computacional utilizado foi:

- Ambiente computacional Onix
  - Onix - SMP (Multiprocessadores Simétricos com Memória Compartilhada)
  - Número de CPUs (*Central Process Unit*): 4
  - Velocidade das CPUs: 200 MHz
  - Memória RAM (*Random Access Memory*): 256 MB
  - Sistemas operacional: Linux Red Hat
  - Linguagem de programação: C ANSI (*American National Standard Institute*)
  - Compilador: gcc

O Onix utiliza apenas um processador para processamento seqüencial. Este foi o primeiro ambiente computacional de simulação, no qual foram realizadas as fases de desenvolvimento e testes preliminares do software desenvolvido.

b) Laboratório de Computação Científica Avançada

O Laboratório de Computação Científica Avançada (LCCA) da USP é um laboratório virtual com recursos de HPC – *High Performance Computing* disponibilizados a todos os pesquisadores da Universidade de São Paulo. Os ambientes computacionais utilizados foram:

- Ambiente computacional Cray SV1
  - Número de CPUs: 8
  - Velocidade das CPUs: 300MHz
  - Memória RAM: 16 GB
  - Memória de disco: 70 GB

- Capacidade de processamento: 9 GFLOPS
- Sistemas operacional: Unix
- Linguagem de programação: C ANSI
- Compilador: cc

O Cray SV1 é um computador vetorial que pode utilizar até 4 processadores simultaneamente para a execução de uma mesma aplicação. O ambiente de simulação Cray SV1 foi utilizado na fase inicial das simulações.

- Ambiente computacional Alcateia

  Configuração dos servidores:

  - Número de CPUs: 4
  - Velocidade das CPUs: Intel XEON 2.4 GHz
  - Memória RAM: 2.5 GB
  - Memória de disco: 72 GB
  - Discos SCSI (*Small Computer System Interfac*e)

  Configuração dos nós:

  - Número de CPUs: 4
  - Velocidade das CPUs: Intel XEON 2.4 GHz
  - Memória RAM: 2.5 GB
  - Memória de disco: 32 GB
  - Discos IDE (*Intergrated Drive Electronics*)

O cluster Alcateia é composto por um servidor principal, denominado de alcatéia, e outro reserva (redundante) de forma a aumentar a disponibilidade do ambiente. Ele é formado por 33 nós, denominados de lobo01 a lobo 33, conectados em topologia estrela ao servidor alcateia. As conexões entre servidores e nós são realizadas através de uma rede local, por intermédio de um *switch* (elemento de interconexão de rede), conforme apresentado na figura 6.2. A capacidade máxima do ambiente é de 132 tarefas (*jobs*) simultâneos.

Ambiente de programação:

- Sistema operacional: Linux
- Linguagem de programação: C ANSI

- Compilador: cc

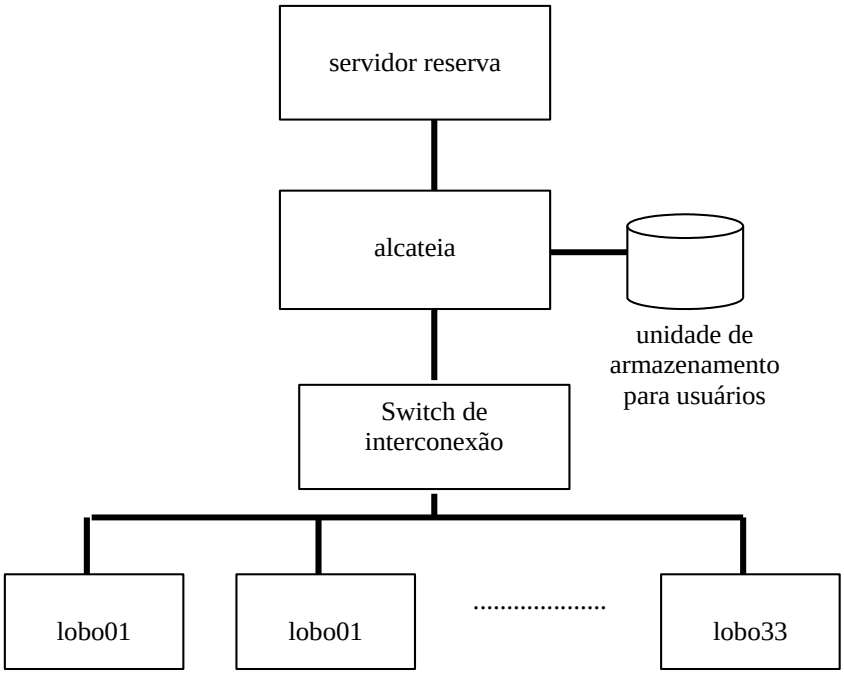

Figura 6.2: Topologia física do ambiente alcateia

6.5 Estratégia de Calibração

De acordo com (FREGNI, 1997), pode-se definir o processo de calibração de um algoritmo genético em macro-calibração e micro-calibração. A eficiência do algoritmo de busca depende destas calibrações. Basicamente, cada uma destas calibrações abrange os seguintes aspectos:

Macro-calibração: define quais diferentes mecanismos podem ser aplicados em cada operador genético.

Micro-calibração: define os valores dos parâmetros internos ao algoritmo genético que interferem diretamente em seu processo de evolução.

O objetivo final do processo de calibração é obter o melhor algoritmo genético (macro-calibração) e seus parâmetros internos (micro-calibração), que maximizem a função objetivo para o problema de otimização de demanda em infra-estrutura aeronáutica pesquisado. Todos estes parâmetros podem interferir diretamente na eficiência do algoritmo e, por conseqüência, na qualidade da solução encontrada.

6.5.1 Sessão e Conjunto de Testes

Os algoritmos genéticos podem ser classificados como métodos estocásticos, no qual os resultados em cada simulação podem ser diferentes. Devido a estas dificuldades, adotou-se os conceitos de sessão e *set* (conjunto de testes) para definir os casos de testes a serem executados dentro do estudo de caso.

- ***Set*:** conjunto de valores definidos (configurados) para os parâmetros de micro-calibiração para um dado algoritmo genético. O *set* é definido pelos parâmetros: taxa de sobreviventes, de reprodução e de mutação, tamanho populacional entre outros. Para os algoritmos genéticos paralelos pode-se adicionalmente acrescentar a taxa de emigrantes e número de ilhas.
- **Sessão:** número fixo de simulações com o objetivo de resolver o problema em estudo.

São utilizados métodos estatísticos, tais como, a média, desvio padrão, entre outros, de forma a diferenciar os *sets* e determinar qual o melhor entre eles.

6.5.2 Análise de Esforço Computacional

Como tentativa de determinar o esforço computacional necessário para se encontrar o melhor algoritmo genético e seu respectivo *set*, foram realizadas as seguintes estimativas:

a) Estimativa do Esforço Computacional

Através de algumas simulações iniciais do algoritmo genético método de seleção por roleta (*roulette whell selection*), com população igual a 500 cromossomos e critério de parada por gerações fixa igual a 1000 gerações, observou-se que as simulações duraram aproximadamente 25 horas no ambiente de simulação Cray SV1. Observou-se que o esforço computacional (EC) em cada simulação é proporcional ao tamanho populacional e ao número de gerações ao final da evolução. Desta forma, uma primeira estimativa do esforço computacional para a obtenção do tempo de simulação, pode ser dado por:

EC = (tamanho da população) x (número de gerações ao final do critério de parada)

Assim, para as simulações realizadas tem-se que:

EC = 500x1000=500.000 cromossomos, apresentando tempo de simulação igual a 25 hs.

b) Estimativa de testes a serem executados

As premissas consideradas para a estimativa dos testes a serem executados são:

- Algoritmos genéticos de simulação: utilizar duas variedades de algoritmos genéticos, métodos de seleção por roleta (*roulette whell selection*) e torneio (*tournament selection selection*).
- *Set*: utilizar três tamanhos de população com tamanhos iguais a 250, 500 e 1000 cromossomos. Para cada uma das opções de tamanho populacional, discretizar os demais parâmetros de micro-calibração e combiná-los em 56 opções, ou seja, 56 *sets* a serem testados.
- Sessões: na literatura observa-se que normalmente são adotadas sessões de tamanhos iguais a 50, 100, 400 etc (FREGNI, 1997). Considera-se aqui sessões de tamanho igual a 50 simulações.
- Critério de parada por gerações: igual a 1000 gerações.

De posse desses valores pode-se estimar o tempo de execução dos diversos testes, conforme a tabela 6.2.

Estimativa de Tempo de Simulação – Estudo de Caso		
População de 250	População de 500	População de 1000
EC = 250.000 cromossomos TS =12:30 hs (estimado) TTP=35.000 hs	EC = 500.000 cromossomos TS =25 hs (medido) TTP=70.000 hs	EC = 1.000.000 cromossomos TS =50 hs (estimado) TTP=140.000 hs
Tempo total = 245.000 hs		

Tabela 6.2: Estimativa de esforço computacional de simulação

Sendo:

EC: Esforço computacional.

TS: Tempo por simulação.

TTP: Tempo por tamanho populacional (2.800 simulações).

Observação:

- Cada simulação com critério de parada por geração de 1000 gerações.
- Estimativas de 56 sessões e 50 simulações por sessão, totalizando 2.800 simulações por tamanho populacional.

Supondo que os algoritmos genéticos, métodos de seleção por roleta e torneio, apresentem o mesmo esforço computacional, ter-se-ia um esforço computacional total de

490.000 hs de simulação. Este valor corresponde aproximadamente a 56,71 anos de simulações realizadas de forma seqüencial, totalmente inviável para um trabalho de pesquisa.

6.5.3 Alternativas para a Realização de Calibração

Foram analisadas duas alternativas para a realização do estudo de caso:

a) Adotar apenas um único algoritmo genético (macro-calibração) e analisar alguns intervalos de valores (*sets*) para os seus parâmetros internos (micro-calibração). Desta forma, poder-se-ia realizar uma análise mais minuciosa de forma a encontrar o melhor *set* para este algoritmo genético.

b) Analisar uma variedade maior de algoritmos genéticos (macro-calibração) testando alguns parâmetros internos (micro-calibração) que pudessem apresentar maior influência sobre o problema em estudo. Caso o esforço computacional para o teste destes parâmetros fosse ainda elevado, optar-se-ia por diminuir a precisão em encontrar o melhor *set* dentre os *sets* estudados, reduzindo-se o tamanho das sessões.

Após um período de análise das duas alternativas optou-se pela segunda opção, pois conclui-se que esta poderia enriquecer mais a pesquisa pelo número de alternativas a serem avaliadas. Além disso, esta alternativa poderia trazer resultados mais interessantes do ponto de vista de abrangência da pesquisa e identificação de novos caminhos a serem investigados.

6.5.4 Processo de Calibração

O processo de calibração foi dividido em três grandes etapas.

- **Calibração dos algoritmos genéticos**

O objetivo desta etapa é encontrar o melhor algoritmo genético (macro-calibração) e seu respectivo *set* (micro-calibração) que apresentem os melhores valores para a função objetivo. Pretende-se encontrar a menor carga de trabalho de gerenciamento global para a demanda e infra-estrutura aeronáutica estudada.

- **Estudos complementares dos algoritmos genéticos**

O objetivo desta etapa é pesquisar algumas alterações em alguns aspectos dos algoritmos genéticos com a intenção de se obter um ganho de otimização adicional nos valores anteriormente obtidos para a função objetivo.

- **Avaliação do modelo de otimização de demanda**

O objetivo desta etapa é verificar o comportamento do modelo de otimização de demanda em função de mudanças (flexibilizações) em parâmetros internos do modelo, bem como, de uma pequena alteração na demanda originalmente utilizada. Este etapa procura apresentar alternativas adicionais para a diminuição da carga de trabalho de gerenciamento global do cenário aeronáutico em estudo.

As análises estatísticas para a determinação dos melhores *sets* foram baseadas em relação a dois tipos de medidas:

- **Função objetivo populacional**: refere-se à média dos valores médios da função objetivo de todos os cromossomos da população em cada simulação, em uma mesma sessão.
- **Função objetivo dos melhores cromossomos**: refere-se à média da função objetivo dos melhores cromossomos da população em cada simulação, em uma mesma sessão. É selecionado o melhor cromossomo em cada simulação.

Estas medidas foram adotadas pois ambas representam melhor o desempenho de cada *set* em relação a função objetivo (aptidão), sendo que a função objetivo populacional fornece uma noção do desempenho médio de cada *set*, e a função objetivo dos melhores cromossomos fornece o desempenho dos melhores resultados obtidos em cada *set*.

6.6 Algoritmos Genéticos Seqüenciais

Nesse item é detalhado o processo de calibração dos algoritmos genéticos seqüenciais em suas três etapas.

6.6.1 Etapa de Calibração

Nesta etapa foram adotadas as seguintes medidas:

a) Foram selecionados três algoritmos genéticos seqüenciais:

- **Método de seleção por roleta:** método selecionado por ser tradicional, proposto originalmente por John H. (HOLLAND, 1995), sendo a base de comparação com os demais métodos.

- **Método de seleção por torneio:** selecionado por ser um método que apresenta bons resultados em diversas aplicações e problemas de alta complexidade, tal como visto em (FREGNI, 1997).
- **Evolução por abelha rainha:** selecionado por ser um processo de evolução normalmente utilizado em problemas de otimização com grande influência do operador genético mutação (JUNG, 2003).

b) Devido ao grande consumo de recursos computacionais foi utilizado preferencialmente o cluster alcatéia do LCCA para as simulações, tanto para as simulações dos algoritmos seqüenciais (devido a grande capacidade de processamento de cada nó do cluster), quanto dos algoritmos genéticos paralelos.

c) Os algoritmos genéticos são métodos estocásticos que necessitam de análises estatísticas de seus dados baseadas em valores médios, desvios padrões e análise de hipóteses para a determinação do melhor *set*. Existe uma grande interdependência entre os diversos parâmetros dos algoritmos genéticos, dificultando o conhecimento da distribuição que realmente o representa.

Normalmente são adotadas distribuições uniforme e a normal como representantes de seu comportamento. Adicionalmente, é adotado um número de sessões que varia entre 50, 100, 400 etc (FREGNI, 1997). Cada um dos valores obtidos através das simulações é considerado uma amostra do ponto de vista de análise estatística.

Devido ao enorme esforço computacional necessário para realizar sessões desta magnitude, optou-se em utilizar sessões de menor tamanho, com valor igual a 10. Observou-se que, apesar desta sessão ser considerada como pequena, alguns trabalhos como (JUNG, 2003) adotam este tamanho de sessão sem realizar nenhum comentário adicional. Para compensar a utilização de sessões de menor tamanho, decidiu-se utilizar a análise estatística, através da teoria das pequenas amostras (MURRAY, 1969) e (OLIVEIRA, 1997). Ela considera amostras com tamanho $n \leq 30$ como amostras de pequeno tamanho, na qual a utilização de distribuições como, por exemplo, a normal não são boas, necessitando de correções convenientes. Uma destas distribuições, que introduz correções, sendo utilizada nesse trabalho de pesquisa é a distribuição denominada de *t-student*. O Apêndice C – Conceitos em

Estatística apresenta os conceitos de média, desvio padrão da distribuição *t-student*, bem como o teste de hipótese adotado. Todos estes conceitos estatísticos são utilizados para diferenciação e seleção dos melhores *sets* dos algoritmos genéticos.

d) Na etapa de calibração todas as simulações realizadas foram com intervalo de amostragem de 60 segundos.

e) A etapa de calibração foi dividida em 6 fases de forma a permitir um menor esforço de calibração, bem como, facilitar e tornar viável a análise dos resultados das otimizações. As fases são:

- **Fase de pré-calibração:** permite observar, através de algumas simulações preliminares sem uma planificação sistemática, quais parâmetros podem ser candidatos a serem mais sensíveis ao problema de otimização de demanda em infra-estrutura aeronáutica. Assim, ao final desta fase, deseja-se que seja selecionado, segundo a percepção e sensibilidade do pesquisador, quais parâmetros podem ser assumidos como de maior influência no problema em análise.
- **Fase de gerações fixas:** nesta fase são criados *sets*, bem como são definidas sessões de 10 simulações. Os *sets* são divididos segundo o tipo de algoritmo genético (métodos de seleção por roleta, torneio e evolução por abelha rainha) e tamanho populacional. O objetivo desta fase é obter os melhores *sets* em função do tipo de algoritmo genético e tamanho populacional, reduzindo o número de *sets* originais. O critério de parada adotado é por número de gerações, já que se consegue maior controle do tempo de duração das simulações e de recursos computacionais.
- **Fase de estabilidade da sessão de 10:** realiza-se a partir dos melhores *sets* obtidos na fase anterior. Nesta fase o critério de parada foi alterado para estabilidade, pois neste caso a parada da evolução ocorre por estagnação da evolução (FREGNI, 1997), podendo fornecer maior qualidade de otimização. Foram adotadas sessões de 10 simulações. O objetivo desta fase é diminuir ainda mais o número de melhores *sets* selecionados na fase de gerações fixas.

- **Fase de estabilidade da sessão de 30:** supondo que exista mais que um *set* em cada um dos grupos definidos por algoritmo genético e tamanho de população da fase anterior, são realizadas adicionalmente mais 20 simulações em cada um destes *sets* remanescentes. Desta forma, são compostas sessões de 30 simulações. O objetivo aqui é procurar reduzir ao máximo o número de melhores *sets* encontrados nas fases anteriores. Deseja-se, nesta fase, encontrar somente um *set* para cada um dos grupos definidos em função do tipo de algoritmo genético e tamanho populacional. Caso não seja possível encontrar apenas um *set*, os *sets* resultantes serão considerados como equivalentes, dentro da estimativa e análise definidas para o trabalho de pesquisa.
- **Fase de testes adicionais:** durante a realização das fases anteriores observou-se que alguns estudos complementares e de pequeno esforço computacional, quando comparados às demais fases, seriam interessantes de serem ainda realizados. O objetivo desta fase é complementar as análises anteriores, realizando-se testes adicionais em relação a parâmetros selecionados, que possam supostamente ainda melhorar a convergência dos algoritmos genéticos. Desta forma, pode-se verificar se estas suposições de alteração de parâmetros aumentam ainda mais o valor da função objetivo utilizada. Para estes testes foram adotadas também sessões de 10 simulações.
- **Fase de seleção global:** nesta fase é realizada novas sessões de 10 simulações, com o objetivo de selecionar o melhor algoritmo genético (macro e micro-calibração), independentemente da divisão até agora adotada, em função do tipo de algoritmo genético e tamanho populacional. O objetivo é encontrar um único algoritmo genético com seu respectivo *set*, que será utilizado nas demais fases da pesquisa.

6.6.2 Etapa de Estudos Complementares

Foi selecionado o algoritmo genético seqüencial e tamanho de população que apresentaram o melhor desempenho, ou seja, o maior valor para a função objetivo na fase de seleção global. O objetivo desta etapa é realizar alguns estudos complementares, em relação a parâmetros específicos não estudados anteriormente: flexibilização do

intervalo de amostragem e discretização do tempo (número de bits que compõem cada cromossomo).

Outro objetivo desta etapa é analisar otimizações para uma futura demanda hipotética, com poucas alterações de vôos, em relação a demanda inicialmente analisada. Neste caso, utiliza-se uma população inicial com os melhores cromossomos (cenários) encontrados para a otimização desta demanda inicial. Esta análise deseja avaliar a qualidade dos resultados obtidos (função objetivo), bem como se existe uma redução do tempo de convergência, quando parte-se de uma população inicial com otimizações (cromossomos) de demandas próximas da futura demanda hipotética.

Este tipo de situação é muito comum em diversos aeroportos em que fatores adversos tais como, condições meteorológicas, modificam e geram atrasos em diversos vôos programados. Desta forma, a etapa de estudos complementares para os algoritmos genéticos seqüenciais foi realizada em quatro fases:

- **Fase de reservatório dos melhores cromossomos:** nesta fase foram selecionados os melhores cromossomos até a fase de seleção global, e criada uma população inicial. Nesta fase foram utilizadas sessões de 10.
- **Fase de pequena alteração de demanda:** igualmente a fase anterior, foi utilizada uma população inicial com os melhores cromossomos obtidos até a fase de seleção global. Adicionalmente, foram realizadas pequenas diferenças na demanda do dia 06/05/2003 através da alteração de horários de decolagem de alguns vôos, de forma a criar-se uma futura demanda hipotética. Foram também utilizadas sessões de 10.
- **Fase de flexibilização do intervalo de amostragem:** nesta fase o melhor par algoritmo genético e *set*, selecionado na fase de seleção global, foi simulado com o menor intervalo de amostragem possível para o ambiente de simulação alcatéia. O objetivo desta fase foi verificar a influência do intervalo de amostragem no processo de otimização. Foram consideradas nesta fase sessões de 10. Finalmente foram realizadas análises comparativas entre os resultados desta fase e os melhores resultados de fases anteriores.
- **Fase de flexibilização do intervalo de discretização:** todas as simulações realizadas até esta fase foram realizadas utilizando-se 5 bits para a discretização do

tempo dentro de cada setor e aeroporto da infra-estrutura aeronáutica estudada. Este número de bits define o tamanho de cada cromossomo dos algoritmos genéticos. Nesta fase, o objetivo é verificar a influência do intervalo de discretização no processo de otimização. Para tanto, o número de bits do intervalo de discretização foi aumentado nesta fase para 8, 10 e 15 bits. A princípio, aumentando o número de bits do intervalo de discretização, deve-se aumentar a precisão dos tempos de permanência de cada janela de tempo, associada aos aeroportos e setores do espaço aéreo, pelo processo de otimização. Foram consideradas nesta fase sessões de 10.

O cenário aeronáutico em estudo apresenta 7017 genes, sendo cada um destes representado nesta fase por 8, 10 e 15 bits. Desta forma, cada cromossomo utilizado durante esta fase da pesquisa foi composto respectivamente por 56.136, 70.170 e 105.255 bits.

6.6.3 Etapa de Avaliação do Modelo de Otimização de Demanda

Nesta etapa foi selecionado o par algoritmo genético seqüencial e tamanho de população que apresentou o melhor desempenho na etapa de calibração. O objetivo desta etapa é realizar estudos em relação aos parâmetros específicos do modelo de otimização de demanda: atrasos em aeroportos críticos e demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos, e janelas de tempo em áreas de controle terminal e espaço aéreo superior.

Desta forma, deseja-se verificar a influência, na carga de trabalho de gerenciamento global, de cada um dos parâmetros considerados no modelo de otimização de demanda. Neste sentido, é fundamental identificar quais parâmetros apresentam maior redução na carga de trabalho de gerenciamento global. Este tipo de análise torna-se bastante relevante e útil em situações em que o tráfego excedente não possa ser reduzido, mesmo após um intensivo processo de otimização. Neste caso, uma opção é flexibilizar um ou mais parâmetros do modelo, preferencialmente aqueles que apresentem maior redução na carga de trabalho de gerenciamento global e tragam o menor impacto aos serviços de transporte aéreo disponibilizados.

Esta etapa foi dividida em duas fases:

- **Fase de análise de parâmetros do modelo:** o objetivo é analisar a influência de cada um dos parâmetros do modelo sobre a carga de trabalho de gerenciamento do cenário aeronáutico.
- **Fase de flexibilização do modelo:** a diferenciação em relação à fase anterior, é que nesta fase os parâmetros são flexibilizados individualmente e em grupo, de forma a avaliar qual a influência da flexibilização dos parâmetros, isoladamente e simultaneamente, dentro do modelo de otimização. Adicionalmente, deseja-se encontrar qual o conjunto de menor flexibilização que melhor viabiliza a solução do problema.

Esta etapa foi realizada somente para os algoritmos genéticos seqüenciais, por estar limitada somente ao modelo de otimização de demanda.

6.7 Algoritmos Genéticos Paralelos

Neste item é detalhado o processo de calibração dos algoritmos genéticos paralelos em suas duas etapas:

6.7.1 Etapa de Calibração

Definiu-se que o algoritmo genético paralelo utiliza em cada ilha uma combinação dos melhores *sets* obtidos nas fases de estabilidade de sessões de 10 e 30 dos algoritmos genéticos seqüenciais. São analisados apenas parâmetros complementares, tais como, taxa de migração e tipo de algoritmo genético em cada ilha. Poderiam ser selecionados outros parâmetros, mas considerou-se a princípio, que estes dois parâmetros seriam mais relevantes de serem analisados.

Esta decisão foi tomada, a princípio, devido ao elevado esforço computacional de calibração dos algoritmos genéticos paralelos, quando comparado aos algoritmos genéticos seqüenciais. O ideal seria realizar a calibração semelhante à realizada para os algoritmos genéticos seqüenciais, mas inviável para este trabalho de pesquisa. Como forma de simplificação, procurou-se estudar apenas os parâmetros particulares dos algoritmos genéticos paralelos, em relação aos algoritmos genéticos seqüenciais. Adotou-se que os demais parâmetros internos (micro-calibração) são constantes e iguais ao dos melhores *sets* obtidos para os algoritmos genéticos seqüenciais, podendo estes até

serem os melhores também para os algoritmos genéticos paralelos. Nessa etapa foram adotadas as seguintes medidas:

a) Conforme apresentado no Capítulo 5, foi seleciona um algoritmo genético paralelo em ponte, como alternativa de comparação com os algoritmos genéticos seqüenciais estudados.

b) Foram adotados os mesmos três tipos de algoritmos genéticos seqüenciais, ou seja, métodos de seleção por roleta, torneio e evolução por abelha rainha.

c) Foram adotados os mesmos métodos analíticos utilizados nos algoritmos genéticos seqüenciais para analisar as diversas simulações realizadas.

d) Foram utilizadas as seguintes fases dos algoritmos genéticos seqüenciais:

- Fase de estabilidade da sessão de 10.
- Fase de estabilidade da sessão de 30.
- Fase de testes adicionais.

A fase de pré-calibração e de gerações fixas não foram adotadas, pois para os algoritmos genéticos paralelos, o número de *sets* a serem testados é significativamente inferior ao dos algoritmos genéticos seqüenciais. A fase de seleção global não foi adotada pois se decidiu utilizar, devido ao elevado esforço computacional e problemas internos ao ambiente de comunicação alcatéia, apenas um único tamanho populacional.

A fase de testes adicionais, diferentemente da fase dos algoritmos genéticos seqüenciais, teve como objetivo analisar, mesmo de forma limitada, a influência dos parâmetros: número de ilhas e adoção de mais de um ponto de estabilidade, para o critério de parada. Estes testes foram realizados somente para o melhor *set* encontrado até a fase de estabilidade da sessão de 30. Foi adotada a análise somente para o melhor *set* encontrado devido à impossibilidade da realização de testes mais exaustivos de outros parâmetros, necessitando de elevado consumo de recursos computacionais, bem como de tempo de simulação.

6.7.2 Etapa de Estudos Complementares

Igualmente aos algoritmos genéticos seqüenciais, foi selecionado o algoritmo genético paralelo que apresentou o melhor desempenho, ou seja, o maior valor para a função

objetivo na fase testes adicionais. O objetivo desta etapa é o mesmo da etapa de estudos complementares dos algoritmos genéticos seqüenciais.

Nesta etapa foram adotadas as seguintes fases:

- Fase de reservatório dos melhores cromossomos.
- Fase de pequena alteração de demanda.
- Fase de flexibilização do intervalo de amostragem.
- Fase de flexibilização do intervalo de discretização.

Nesta etapa não foi realizada a fase de flexibilização do intervalo de discretização para 10 e 15 bits. Foram utilizadas subpopulações igual a 250 cromossomos em cada ilha. Essas medidas tornaram-se necessárias pois observou-se que o mecanismo de comunicação MPI (*messege passing interface*) apresentou limitações em função do tamanho das informações passadas entre as ilhas (cromossomos migrantes). Quanto maior for o tamanho populacional, maior o número de cromossomos migrantes, dado pela taxa de migrantes. Quanto maior o intervalo de discretização, maior será o tamanho cromossômico.

Foram também realizadas análises comparativas entre algoritmos genéticos seqüenciais e paralelos nas seguintes fases: estabilidade de sessão de 30, reservatório dos melhores cromossomos, pequena alteração de demanda e flexibilização do intervalo de amostragem.

6.8 Resultados do Processo de Calibração dos Algoritmos Genéticos Seqüenciais

A seguir são apresentados os resultados obtidos em cada uma das etapas do processo de calibração dos algoritmos genéticos seqüenciais.

6.8.1 Etapa de Calibração

A seguir são apresentados os resultados obtidos em cada uma das fases da etapa de calibração dos algoritmos genéticos seqüenciais.

6.8.1.1 Fase de pré-calibração

Foram realizadas diversas simulações utilizando-se os algoritmos genéticos métodos de seleção por roleta e torneio, e evolução por abelha rainha, variando-se parâmetros como

tamanho da população, taxas de mutação e reprodução, penalidades, tamanho da população de torneio (*q*) para o método de seleção por torneio, entre outros. Foi utilizado o ambiente de simulação Cray SV1 e adotado o intervalo de amostragem igual a 60 segundos.

Análises e comentários gerais desta fase

Análises preliminares mostraram que alguns parâmetros poderiam ser mais sensíveis ao problema de otimização de demanda.

O tempo de execução das simulações com intervalo de amostragem inferior a 60 segundos, aumentava significativamente. O ideal seria utilizar intervalo de amostragem igual a 1 segundo, devido à maior precisão dos valores medidos em relação à demanda real. Mas este valor tornava-se, a princípio, inviável para um estudo de maior abrangência quanto à utilização de diferentes tipos de algoritmos genéticos e parâmetros a serem analisados.

Observou-se também que o intervalo de amostragem interfere na qualidade da solução encontrada, pois quanto maior o intervalo de amostragem, maior era o erro em relação à demanda real.

O operador mutação apresentou elevada influência na evolução dos algoritmos genéticos. Foi testada uma alternativa do operador mutação com mais de um ponto de mutação. Observou-se que, utilizando-se 5 pontos de mutação simultâneos e, para taxas de mutação elevadas, apresentava um melhor desempenho (função objetivo[1]) dos algoritmos genéticos quando comparado à adoção de um único ponto de mutação. Normalmente, é sugerido apenas 1 ponto de mutação nas diversas literaturas ligadas aos algoritmos genéticos (FREGNI, 1997) e (PAZ, 2000), pois normalmente a utilização intensiva deste operador mostra-se muito mais destrutiva que construtiva em muitos problemas.

Uma possível justificativa para a grande influência do operador mutação na função objetivo esteja relacionada ao seu tamanho cromossômico. Este pode ser considerado

[1] A partir deste ponto a função objetivo populacional e dos melhores cromossomos serão identificadas indistintamente como função objetivo. Quando o contexto necessitar de uma ou ambas as expressões de forma destacada, elas serão citadas por extenso.

suficientemente grande, de forma que a aplicação de apenas 1 ponto de mutação apresente um ganho relativamente pequeno, em termos de função objetivo, quando comparado à adoção de mais de um ponto de mutação simultâneo, com altas taxas de mutação. Neste caso, o acréscimo da função objetivo entre gerações, durante o processo evolutivo, tornou-se mais eficaz com mais de 1 ponto de mutação simultâneo, e taxas elevadas de mutação, trazendo melhores resultados ao final da otimização.

O operador permutação não apresentou grande influência na evolução dos algoritmos genéticos, sendo que valores da taxa de reprodução acima de 50% podem apresentar algum ganho quanto à otimização. Uma possível justificativa é que não ocorram ganhos significativos através do operador permutação, quando se trabalha com cenários muito próximos dentro do contexto aeronáutico.

Intui-se que quanto maior o tamanho da população, maior o valor da função objetivo. Populações pequenas, com tamanhos iguais a 20, 50 e 100 cromossomos aparentemente apresentam menor evolução, quando comparados a populações maiores. Foram testados também tamanhos de população iguais a 250, 500 e 1000 cromossomos que, apresentaram melhores resultados quando comparados aos demais tamanhos de população testados.

A taxa de sobreviventes não apresentou grande influência no valor da função objetivo. Observou-se que o número de cromossomos de melhor aptidão aumentavam na população com o aumento desta taxa. Aparentemente foram obtidos melhores resultados com taxas de sobreviventes igual a 20% para os algoritmos genéticos métodos de seleção por roleta e torneio, e igual a 2% para evolução por abelha rainha.

Para o algoritmo genético método de seleção por torneio, observou-se que com as populações de torneio de tamanho q igual a 2 puderam ser obtidos melhores resultados ao final do processo de otimização.

O critério de parada por estabilidade pode aumentar, em muito, o esforço computacional de simulação. Observou-se que o critério de parada por número de gerações em torno de 1000 mostrou ser um valor razoável. Este número de gerações pode não ser suficiente se for utilizado o critério de parada por estabilidade. No entanto, a adoção deste critério de

parada por estabilidade foi inviável em função do número e tempo de simulação dos *sets* a serem testados.

Valores inferior a estes, principalmente para o número de gerações, apesar de reduzir o tempo de convergência, apresentavam valores significativamente inferiores para a função objetivo. O número de gerações pelo critério de parada por estabilidade estaria em torno de 6000 gerações ou mais, para os algoritmos genéticos seleção por roleta e torneio. Para o algoritmo genético evolução por abelha rainha estaria em torno de 3000 gerações, mas com valores da função objetivo inferiores aos dois outros algoritmos genéticos estudados. Esta redução significativa na geração de estabilidade, para o algoritmo genético evolução por abelha rainha, provavelmente esteja associada à forma de evolução deste algoritmo genético, no qual a exploração do espaço de pesquisa é realizada de forma mais abrupta em relação aos demais algoritmos genéticos. A desvantagem é que podem ocorrer convergências mais prematuras para máximos locais, resultando numa função objetivo inferior.

Observou também que, se adotando penalidade igual a 50 quando o $WL_{\text{instantâneo do setor}} \leq 50$ (entre as linhas de congestionamento e saturação aceitável), e penalidade igual a 500 quando o $WL_{\text{instantâneo do setor}} > 50$ (acima da linha de saturação aceitável, ou seja, supersaturação), as simulações apresentavam os melhores resultados na função objetivo. Quando os valores de penalidades eram superiores, principalmente para valores maiores que 1000 para a linha de saturação aceitável, observou-se que uma parte da população, principalmente no algoritmo genético por evolução por abelha rainha, apresentava alguns cromossomos com valor de função objetivo bem abaixo dos valores encontrados para os melhores cromossomos da mesma população. Em contra partida, quando as penalidades adotadas eram muito baixas, o tempo de convergência dos algoritmos genéticos aumentava significativamente, tornando-se ainda mais inviável a realização de testes exaustivos.

Adotou-se que os intervalos de discretização de tempo Id_i são binários. Sendo 2^w o número de amostragens possíveis em cada setor assumiu-se, após algumas simulações, w=5 bits para a discretização do tempo em cada setor (32 intervalos para todos os setores do cenário aeronáutico analisado). Esta adoção, a princípio, contemplava

intervalos de tempos que podiam apresentar bons resultados durante o processo de otimização. Sabendo-se que o cenário aeronáutico em estudo apresenta 7.017 genes e sendo, cada um destes representado por 5 bits, tem-se que cada cromossomo utilizado durante a pesquisa é composto por 35.085 bits.

Adotou-se, de forma arbitrária, para a função objetivo (FO) o fator 2.10^7 como numerador, de forma a normalizar os valores da função objetivo. Sem esta normalização os valores da função objetivo apresentariam valores extremamente pequenos. Assim, a função objetivo adota foi:

$$FO_{\max imizar} = \frac{2.10^7}{WL_{cenário\,aeronáutio}} \quad \text{(equação 1)}$$

Esta fase durou aproximadamente 3 meses entre simulações e análises. Ao final desta fase havia informações suficientes para a planificação e composição dos *sets* para as fases seguintes.

6.8.1.2 Fase de Gerações Fixas

A partir dos resultados e das análises obtidas na fase de pré-calibração, foram assumidas para esta fase, as seguintes premissas:

- Todas as sessões dessa fase foram compostas de 10 simulações.
- Procurou-se sempre executar o máximo de simulações simultâneas. O ambiente de simulação alcatéia permitia, no momento, a execução de até 32 *jobs* simultâneos, disputados por diversos pesquisadores da Universidade de São Paulo.
- Foi escolhido *sets* associados a alguns parâmetros, segundo a importância relativa de cada parâmetro, obtida durante a fase de pré-calibração.
- Para os algoritmos genéticos método de seleção por roleta e torneio foram criados e testados 54 *sets*, apresentando os seguintes valores para cada um dos parâmetros:

  - População: contendo três valores de 250, 500 e 1000 cromossomos.

  - Sobreviventes (x%): igual a 20% (fixo)

  - Taxa de reprodução (t_r): contendo três valores de 50%, 70% e 90%.

  - Taxa de mutação (t_m): contendo seis valores de 10%, 20%, 30%, 50%, 70% e 90%.

  - Pontos de mutação (PM): igual a 5 pontos de mutações simultâneos.

- Para o algoritmo genético evolução por abelha rainha foi deteminado que seriam criados e testados 96 *sets*, apresentando os seguintes valores para os parâmetros:
  - População: contendo três valores de 250, 500 e 1000 cromossomos.
  - Sobreviventes: igual a 2% (fixo).
  - Taxa de reprodução: contendo dois valores de 70% e 90%.
  - Taxa de mutação normal (ε): contendo dois valores de 10% e 40%.
  - Probabilidade de mutação normal (p_{mn}): contendo dois valores de 60% e 80%.
  - Probabilidade de supermutação (p_{sm}): contendo dois valores de 80% e 100%.
  - Pontos de mutação nomal (PMN): igual a 5 pontos de mutação simultâneos.
  - Pontos de supermutação (PSM): contendo dois valores de 5 e 10 pontos de mutação simultâneos.
- Para análise de cada um dos *sets* simulados, em cada algoritmo genético, foram obtidos os seguintes dados :
  - Média do número de gerações para o surgimento da melhor solução (cromossomo) em relação à função objetivo.
  - Número médio de gerações criadas.
  - Número médio de cromossomos criados (esforço computacional).
  - Função objetivo populacional.
  - Desvio padrão da função objetivo populacional.
  - Função objetivo dos melhores cromossomos.
  - Desvio padrão da função objetivo dos melhores cromossomos.
  - Tempo médio de processamento de cada simulação.
  - Tempo total de processamento para as 10 simulações por sessão.

  O Apêndice D – Resultados dos Algoritmos Genéticos Seqüenciais e o Apêndice E – Resultados dos Algoritmos Genéticos Paralelos apresentam todos os resultados experimentais obtidos neste trabalho de pesquisa.
- Na seleção dos melhores *sets* utilizou-se a análise estatística baseada na média aritmética e desvio padrão populacional e do melhores cromossomos de cada sessão estudada. Adicionalmente, foi utilizada a distribuição *t-student* com 9 graus de

liberdade, e intervalo de confiança de 95%. A seleção dos melhores *sets* é realizada através de testes de hipótese (consulte o Apêndice C – Conceitos em Estatística).

O objetivo do processo de otimização é encontrar a maior função objetivo. Entretanto, os algoritmos genéticos são processos estocásticos, ou seja, são não determinísticos e variam ao longo do tempo de forma imprevisível (BRANCO, 2001). Desta forma, a utilização de parâmetros como a média e desvio padrão e teste de hipótese tornam-se mais adequados para uma melhor estimativa e análise dos resultados obtidos. As análises dos resultados obtidos são apresentados a seguir.

O item F.1.1 - Fase de Gerações Fixas do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese para esta fase.

Análises e comentários desta fase

Os algoritmos genéticos seleção por roleta e torneio apresentaram para os mesmos tamanhos populacionais, até 1000 gerações, tempos de simulação bastante próximos.

A função objetivo para o algoritmo genético seleção por torneio foi ligeiramente superior ao algoritmo genético seleção por roleta.

A função objetivo foi significativamente melhor para o algoritmo genético evolução por abelha rainha, quando comparada aos demais algoritmos genéticos. Este fato justifica-se devido à forma de evolução deste algoritmo genético, que aumenta significativamente a sua velocidade de exploração (JUNG, 2003) e convergência, fazendo com que maiores valores da função objetivo sejam atingidas em um menor número de gerações.

Observou-se que para o algoritmo genético evolução por abelha rainha houve uma redução significativa no tempo de processamento, quando comparado aos demais algoritmos genéticos, para um mesmo número fixo de gerações para o critério de parada. Este fato justifica-se pela forma de evolução deste algoritmo genético ser mais eficiente até este ponto da pesquisa.

O desvio padrão da função objetivo foi semelhante entre os três algoritmos genéticos.

Para os três algoritmos genéticos estudados, o tempo de processamento cresce, aproximadamente, de forma linear com o tamanho populacional.

Observou-se que, para os algoritmos genéticos seleção por roleta e torneio, muitos dos *sets* selecionados como melhores são idênticos para ambos. Este fato sugere que existam valores de parâmetros que são semelhantes e favoráveis a melhor evolução destes algoritmos genéticos.

O operador permutação aparentemente apresenta papel secundário em relação ao operador mutação, considerado, até o momento, o principal operador para o modelo de otimização de demanda.

Observou-se, pelos testes de hipótese, que um maior número de *sets* são encontrados como equivalentes para o algoritmo genético evolução por abelha rainha, em relação aos demais algoritmos genéticos. Este fato pode ser justificado pela forte característica de exploração deste algoritmo genético, onde a abelha rainha (cromossomo de maior aptidão) cruza (operador permutação) com os zangões (demais cromossomos selecionados para o cruzamento). Este fato também aumenta, de forma significativa, a probabilidade de ocorrer uma convergência prematura do algoritmo genético (JUNG, 2003) em um máximo local.

Os três algoritmos genéticos estudados apresentarem, em média, uma elevada taxa de mutação. Este fato mostra que este parâmetro pode ter grande importância e influência para o problema de otimização de demanda em infra-estrutura aeronáutica. Este fato torna-se mais destacado se for considerado que foram adotados 5 pontos de mutação simultâneos para os algoritmos genéticos seleção por roleta e torneio. Igualmente, para o algoritmo genético evolução por abelha rainha, com 5 e 10 pontos de mutação simultâneos para a taxa de mutação normal e supermutação respectivamente, muitos *sets* foram selecionados como melhores. Uma possível justificativa para este fato é que a cadeia cromossômica é extremamente longa para o modelo de otimização de demanda proposto, apresentando 35.018 bits que podem ser alterados pelo operador mutação. Uma única alteração deste parâmetro trás um pequeno ganho. No entanto, quando utilizado o operador mutação com vários pontos simultaneamente e com alta probabilidade (alta taxa de mutação), obtém-se melhores resultados no processo de evolução (otimização).

6.8.1.3 Fase de Estabilidade de Sessão de 10

Em relação a esta fase foram consideradas as seguintes premissas:

- Critério de parada adotado foi de estabilidade de 10% dos melhores cromossomos da população ficarem estáveis durante 300 gerações.
- Todas as sessões dessa fase foram compostas de 10 simulações.
- Os *sets* iniciais para simulações desta fase são os *sets* selecionados na fase de gerações fixas.

O item F.1.2 - Fase de Estabilidade Sessão de 10 do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Observou-se que foi necessário um número bem superior de gerações para atingir a estabilidade da evolução dos algoritmos genéticos estudados, em relação à fase de gerações fixas.

Para os algoritmos genéticos seleção por roleta e torneio houve uma redução sensível do número de *sets* selecionados como melhores ao final desta fase. Para o algoritmo genéticos evolução por abelha rainha observou-se que um número bem maior de *sets* ainda foram selecionados como melhores. Esta fato pode ser justificado também pela forma de exploração deste algoritmo genético. Esta forma de exploração torna este algoritmo genético mais susceptível a convergências prematuras, apesar do elevado número de pontos, taxas e probabilidades de mutação.

Aparentemente, para os três algoritmos genéticos a função objetivo cresce com o tamanho populacional.

O tempo de processamento de cada simulação, de uma forma aproximada, cresce linearmente com o tamanho populacional para os três algoritmos genéticos estudados.

Os desvio padrão da função objetivo foi semelhante para os três tamanhos populacionais (250, 500 e 1000 cromossomos).

Em média, o desvio padrão da função objetivo é inferior em relação ao obtido na fase de gerações fixas. Este fato pode ser justificado pela mudança de critério de parada, de gerações fixas para o de estabilidade. Vale ressaltar que neste critério de parada deve-se

ter um certo número de cromossomos estáveis (aptidão inalterada) por um determinado número de gerações. Assim, o critério por estabilidade diminui a diversidade genética e aumenta a pressão seletiva, fazendo com que os valores da função objetivo, ao final da evolução, tendam a um valor próximo ou igual ao máximo global procurado, desde que não haja convergências prematuras.

O operador mutação mostrou-se ainda mais relevante para a aplicação em estudo dado que, de um modo geral, os *sets* selecionados como melhores apresentaram taxas de mutação elevadas.

Verificou-se aqui também que o operador permutação pode ser considerado como operador secundário, dado que os *sets* selecionados como melhores nesta fase, de um modo geral, apresentaram valores diferentes com relação a este operador.

Muitos *sets* selecionados como melhores apresentaram os mesmos valores para os parâmetros internos dos algoritmos genéticos (micro-calibração). Este fato mostra que deve haver um valor para estes parâmetros internos que maximizem a otimização, podendo ser comum aos diferentes algoritmos genéticos estudados.

Nesta fase, para os algoritmos genéticos seleção por roleta e torneio, conseguiu-se encontrar um único *set* como o melhor para alguns tamanhos populacionais.

A função objetivo para o algoritmo genético evolução por abelha rainha foi em média inferior em relação aos algoritmos genéticos seleção por roleta e torneio. Provavelmente, o problema em análise apresente diversos pontos de máximos locais, e o algoritmo genético evolução por abelha rainha seja mais sensível a convergências prematuras para estes pontos.

O algoritmo genético seleção por torneio, população de 1000 cromossomos, apresentou desempenho (função objetivo) significativamente melhor em relação aos demais algoritmos genéticos e tamanhos populacionais. Este fato é um indício que este algoritmo genético e tamanho populacional sejam os melhores para o problema estudado.

O número de gerações para o critério de parada por estabilidade do algoritmo genético evolução por abelha rainha foi significativamente inferior aos algoritmos genéticos seleção por roleta e torneio. Desta forma, o tempo de processamento de convergência do

algoritmo genético evolução por abelha rainha foi significativamente inferior aos algoritmos genéticos seleção por roleta e torneio.

6..8.1.4 Fase de Estabilidade de Sessão de 30

Em relação a esta fase foram consideradas as seguintes premissas:

- Critério de parada adotado foi de estabilidade de 10% dos melhores cromossomos da população ficarem estáveis durante 300 gerações.
- Com o objetivo de aumentar a precisão dos testes de hipótese, através de um maior número de amostras, as sessões dessa fase passaram a ser compostas de 30 simulações. Sessões de 30 são consideradas ainda como pequenas amostras, devendo ser analisadas pela teoria das pequenas amostras (MURRAY, 1969), sendo aqui também adotada a distribuição *t-student*.
- Os *sets* iniciais para as simulações desta fase são os *sets* selecionados na fase de estabilidade de sessão de 10.
- Foram consideradas as simulações da fase de estabilidade de sessão de 10 para compor as 30 simulações por sessão para esta fase.
- Decidiu-se que, para a próxima fase, deverá existir apenas um *set* para cada algoritmo genético e tamanho populacional, em função do volume de análises até aqui realizadas. Desta forma, adotou-se como critério de desempate entre *sets*, caso exista ao final desta fase mais de um *set* selecionado como melhor, aquele que apresente a maior função objetivo dos melhores cromossomos. Este critério foi adotado em função do objetivo final de sempre se obter os melhores resultados (função objetivo), ou seja, a maior redução de carga de trabalho, ao final das otimizações. Vale a pena ressaltar que esse critério foi adotado simplesmente como forma de prosseguimento para os passos seguintes da pesquisa.

O item F.1.3 - Fase de Estabilidade Sessão de 30 do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

<u>Análises e comentários desta fase</u>

Para a sessão de 30 conseguiu-se uma redução sensível dos melhores *sets* para cada um dos algoritmos genéticos e tamanhos populacionais estudados. Vale destacar que o

algoritmo genético seleção por torneio com tamanho populacional de 1000 cromossomos e o algoritmo genético evolução por abelha rainha com tamanhos populacionais iguais a 250 e 1000 cromossomos, apresentaram dois *sets* como melhores e equivalentes. Talvez a adoção de uma sessão maior que 30 poderia diferenciá-los em termos de aptidão (função objetivo).

Observou-se que, para o algoritmo genético evolução por abelha rainha, os *sets* selecionados como melhores, apresentaram a probabilidade de supermutação igual a 80%, e a taxa de mutação normal igual a 10%. Este fato mostrou que pode haver uma dependência e um equilíbrio entre estes parâmetros, igualmente a outros parâmetros que interferem no operador mutação. Ou seja, os valores obtidos para estes parâmetros podem estar próximos dos valores que maximizam a otimização (função objetivo). Outro fato importante é que estes valores foram coincidentes em todos os *sets* selecionados deste algoritmo genético, independente do tamanho populacional. Este fato é um indício que estes valores podem estar próximos dos valores ótimos. Também foi observado, para este algoritmo genético, que 10 pontos de mutação simultâneos para probabilidade de supermutação foram encontrados em todos os melhores *sets* selecionados em todos os tamanhos populacionais estudados.

A principal característica observada em todos os *sets* selecionados como melhores, independente do algoritmo genético, é que valores elevados para os parâmetros relacionados ao operador mutação foram mais adequados. Esta característica se destaca mais se for observado que foram adotados vários pontos de mutação simultâneos. A justificativa para este resultado está relacionada à longa cadeia cromossômica utilizada pelo modelo de otimização de demanda proposto. Neste caso, a aplicação do operador mutação traz maiores benefícios ao processo evolutivo (ganho na função objetivo a cada geração) do que a aplicação de um único ponto de mutação.

6.8.1.5 Fase de Testes Adicionais

Foram realizados alguns testes adicionais para avaliar a influência de alguns parâmetros (micro-calibração) na convergência dos algoritmos genéticos. Nessa fase de testes adicionais foram adotadas algumas medidas, discutidas a seguir:

a) Pontos de mutação

Observou-se que durante as simulações dos diversos *sets*, principalmente para o algoritmo genético evolução por abelha rainha, os valores da função objetivo apresentavam uma grande variação dentro de um mesmo *set*. Levantou-se a hipótese que se reduzindo o número de pontos de mutação, em um certo ponto da evolução, pudesse aumentar o ponto de convergência do algoritmo genético. Uma justificativa seria que, em certos estágios da evolução, devido ao efeito abrupto da mutação, ter-se-ia maior probabilidade de serem gerados cenários (cromossomos) aeronáuticos com função objetivo ruins, impedindo assim alguma evolução adicional dos algoritmos genéticos. Em certos estágios da evolução, pequenas alterações (mutações) nas janelas de tempo das aeronaves poderiam ser mais efetivas em termos de redução de carga de trabalho, em relação a alterações mais abruptas (mais de um ponto de mutação simultâneo). Assim, criou-se o conceito de dois pontos de estabilidade para o critério de parada. Quando alcançado o primeiro ponto de estabilidade, automaticamente inicia-se a procura do segundo. Na transição do primeiro para o segundo ponto de estabilidade, um ou mais parâmetros (micro-calibração) podem ser alterados. No caso específico dos pontos de mutação foi adotado que os pontos de mutação são "chaveados" de 5 pontos simultâneos para 1 ponto único de mutação.

Adicionalmente, decidiu-se também aumentar o número de gerações do segundo ponto de estabilidade, em relação ao primeiro ponto, com o objetivo de aumentar-se ainda mais o esforço em conseguir-se um ganho adicional na função objetivo. Desta forma, foram adotados dois pontos de estabilidade, para o critério de parada do algoritmo genético, conforme a seguir:

- Critério do primeiro ponto de estabilidade: estabilidade de 10% dos melhores cromossomos durante 300 gerações. Até que este critério seja atingido é aplicado 5 pontos de mutação simultâneos.
- Critério do segundo ponto de estabilidade: estabilidade de 10% dos melhores cromossomos durante 500 gerações. Após o estabelecimento do primeiro ponto de estabilidade e até ser atingido este segundo critério de estabilidade é aplicado somente 1 ponto de mutação.

Procura-se verificar se a adoção de 1 ponto de mutação desde o início do processo evolutivo, não seria melhor do que 5 pontos de mutação simultâneos. Esta verificação foi necessária devido à constatação de que a existência de valores elevados de pontos de mutação apresentavam conseqüências mais destrutivas do que construtivas.

b) Porcentagem de cromossomos no critério de parada

Verificar se a redução da porcentagem de cromossomos no critério de parada pode melhorar a convergência dos algoritmos genéticos, sendo sugerida a redução de 10% para 1%.

c) Taxa de sobreviventes

Verificar se a redução da taxa de sobreviventes melhora a convergência dos algoritmos genéticos.

d) Número de gerações de estabilidade no critério de parada

Verificar se a variação do número de gerações de estabilidade no critério de parada afeta sensivelmente ou não a convergência dos algoritmos genéticos.

e) Tamanho populacional

Para obter-se uma variabilidade de testes ainda maior nesta fase, foram utilizados os três algoritmos genéticos estudados, mas com tamanhos populacionais diferentes, selecionados de forma arbitrária. Para cada algoritmo genético e tamanho populacional selecionado, foi utilizado o melhor *set* encontrado até a Fase de Estabilidade de Sessão de 30, ou seja:

- Algoritmo genético método de seleção por roleta: *set* 18, população de 1000.
- Algoritmo genético método de seleção por torneio: *set* 12, população de 250.
- Algoritmo genético evolução por abelha rainha: *set* 19, população de 500.

Para os *sets* apresentados e, em função dos parâmetros a serem avaliados, foram criados novos *sets* a serem analisados, para cada um dos algoritmos genéticos.

Para os algoritmos genéticos métodos de seleção por roleta e torneio foram criados 7 novos *sets* para cada um deles, descrito na tabela 6.3.

Sendo:

CP: Critério de Parada composto pela porcentagem de cromossomos (PC) inalterados (mesmo valor da função objetivo), durante um número de gerações (Ge) fixados a priori.

PM: Pontos de Mutação.

PP: Primeiro ponto de parada.

SP: Segundo ponto de parada.

TM: Taxa de mutação.

TR: Taxa de reprodução.

TP: Tamanho populacional.

TS: Taxa de sobreviventes.

Roleta e Torneio

				CP					
				PP			**SP**		
Set	**TS**	**TR**	**TM**	**PM**	**PC**	**Ge**	**PM**	**PC**	**Ge**
01	20%	90%	90%	5	10%	300	-	-	-
02	20%	90%	90%	1	10%	300	-	-	-
03	20%	90%	90%	1	10%	500	-	-	-
04	1%	90%	90%	5	1%	300	-	-	-
05	1%	90%	90%	1	10%	500	-	-	-
06	1%	90%	90%	5	1%	300	1	1%	500
07	20%	90%	90%	5	10%	300	1	10%	500

Obs.: TP igual a 500 cromossomos para o algoritmo genético seleção por roleta e igual a 250 para o algoritmo genético seleção por torneio.

Tabela 6.3: *Sets* criados para o algoritmo genético seleção por roleta e torneio

Para o algoritmo genético evolução por abelha rainha foram criados 4 novos *sets*, descritos na tabela 6.4.

Sendo:

PSM: Pontos de supermutação.

PrMN: Probabilidade de mutação normal.

PMN: Pontos de mutação normal.

PrSM: Probabilidade de supermutação.

TN: Taxa de mutação normal.

Abelha Rainha

							CP							
							PP				SP			
S	**TP**	**TS**	**TR**	**TN**	**PrMN**	**PrSM**	**PN**	**PS**	**PC**	**Ge**	**PMN**	**PSM**	**PC**	**Ge**
01	500	2%	70%	10%	80%	80%	5	10	10%	300	-	-	-	-
02	500	2%	70%	10%	80%	80%	5	5	10%	300	-	-	-	-
03	500	4%	70%	10%	80%	80%	1	3	10%	500	-	-	-	-
04	500	2%	70%	10%	80%	80%	5	10	10%	300	1	3	10%	500

Tabela 6.4: *Sets* criados para o algoritmo genético evolução por abelha rainha

O item F.1.4 - Fase de Testes Adicionais do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Observou-se que, de forma geral, houve um ganho em termos de otimização da função objetivo, com a adoção de um segundo ponto de estabilidade para o critério de parada. Este segundo ponto de estabilidade tem como característica a redução dos pontos de mutação simultâneos.

O que provavelmente ocorre é que a aplicação intensiva do operador mutação, em estágios mais avançados de evolução, apesar de aumentar a diversidade genética, aumenta, em muito, a probabilidade de criação de cenários aeronáuticos ruins (destrutivos). Desta forma, o processo de evolução se estagna na melhor função objetivo até então obtida. Nestes estágios de evolução, pequenas alterações ocasionadas pelo operador mutação (um único ponto de mutação) acabam sendo mais eficientes. Esta adoção apresentou um ganho no processo de evolução para os três algoritmos genéticos estudados.

Adicionalmente, a adoção de 5 pontos de mutação simultâneos desde o início da evolução apresentou bons resultados para os algoritmos genéticos seleção por roleta e torneio. Para o algoritmo genético evolução por abelha rainha deveria ser realizada sessões de 30 simulações para procurar comprovar este fato. Na realidade, com sessões de 10 simulações não se conseguiu diferenciar, se com 5 ou 10 pontos de mutação

simultâneos para a probabilidade de supermutação, qual deles apresentava melhor desempenho quanto a função objetivo.

Fato relevante a ser destacado é que entre os diversos testes adicionais, apenas a adoção dos dois pontos de estabilidade para o critério de parada apresentou melhora efetiva sendo, portanto, o adotado nas demais fases a partir deste ponto da pesquisa. Os valores dos demais parâmetros permaneceram inalterados.

6.8.1.6 Fase de Seleção Global

Foram selecionados, pelos testes de hipótese, os melhores *sets* para cada algoritmo genético e tamanho populacional estudado. As tabelas 6.5 a 6.7 apresentam os melhores *sets* selecionados por tipo de algoritmo genético e tamanho populacional.

População de 250 cromossomos

Set	**AG**	**TS**	**TR**	**TM**	**PM**	**PrMN**	**PS**	**PrSM**
06	Roleta	20%	50%	90%	5	-	-	-
12	Torneio	20%	70%	90%	5	-	-	-
27	Abelha Rainha	2%	90%	10%	5	80%	10	80%

Tabela 6.5: Melhores *sets* para população de 250 cromossomos

População de 500 cromossomos

Set	**AG**	**TS**	**TR**	**TM**	**PM**	**PrMN**	**PS**	**PrSM**
06	Roleta	20%	50%	90%	5	-	-	-
12	Torneio	20%	70%	90%	5	-	-	-
19	Abelha Rainha	2%	70%	10%	5	80%	10	80%

Tabela 6.6: Melhores *sets* para população de 500 cromossomos

População de 1000 cromossomos

Set	**AG**	**TS**	**TR**	**TM**	**PM**	**PrMN**	**PS**	**PrSM**
18	Roleta	20%	90%	90%	5	-	-	-
06	Torneio	20%	50%	90%	5	-	-	-
25	Abelha Rainha	2%	90%	10%	5	60%	10	80%

Tabela 6.7: Melhores *sets* para população de 1000 cromossomos

Ao final desta fase também foi selecionado o melhor algoritmo genético e seu correspondente *set*, independente do tamanho populacional. Este algoritmo genético e respectivo *set* será considerado o que apresenta melhores resultados para o problema de otimização estudado. Este algoritmo genético e *set* foram utilizados nas demais fases, que tem como objetivo o estudo do modelo de otimização através da análise de seus

parâmetros internos (tipos de janelas de tempo), considerando que a etapa de calibração tenha sido finalizada.

Todas as sessões dessa fase foram compostas de 10 simulações, considerando dois pontos de estabilidade para o critério de parada.

O item F.1.5 - Fase de Seleção Global do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Observou-se que para os três tamanhos populacionais estudados o algoritmo genético seleção por torneio apresentou os melhores resultados em termos de evolução (função objetivo).

O *set* 06, população de 1000 cromossomos, do algoritmo genético seleção por torneio pode ser considerado como o mais adequado a ser utilizado para o problema de otimização de demanda em infra-estrutura aeronáutica, pois este algoritmo genético e *set* apresentaram os maiores valores da função objetivo. Este algoritmo genético e *set* foram adotados como referência para as demais fases a serem realizadas neste trabalho de pesquisa.

O fato do tempo de processamento, de uma forma geral, cresce aproximadamente de forma linear com o tamanho populacional, pode tornar-se restritivo em algumas situações, principalmente naquelas em que o tempo de solução é fundamental. Vale destacar que a convergência dos melhores *sets*, que ocorrem para os algoritmos genéticos seleção por roleta e torneio com população igual a 1000 cromossomos, demoraram em média 70 hs ou mais para convergir. Este tempo de convergência impõe que o modelo de otimização de demanda é mais viável na fase de planejamento estratégico, em que normalmente o tempo de convergência observado ainda não é restritivo. Esta fase de planejamento ocorre meses antes do dia efetivo da operação.

Para a fase de planejamento pré-tático, que ocorre na véspera da operação, o modelo pode até ser adotado desde que sejam utilizados *sets* com redução sensivelmente do tempo de convergência. Isto pode ser conseguido através da adoção de tamanhos populacionais menores e menor número de gerações de estabilidade para o critério de

parada. Neste aspecto vale a utilização de *sets* com o algoritmo genético evolução por abelha rainha, que apresentou o menor tempo de convergência entre os três algoritmos genéticos estudados. A qualidade de otimização poderá ser significativamente inferior ao melhor *set* encontrado até o momento (*set* 06 da população de 1000 cromossomos do algoritmo genético seleção por torneio).

A adoção desse modelo de otimização na fase de planejamento tático pode tornar-se inviável, dado que as soluções devem ser fornecidas no mesmo dia (menos de 24 horas).

Observou-se que o operador mutação apresenta grande influência no problema estudado, dado ao alto valor utilizado no *set* selecionado (90%).

6.8.2 Etapa de Estudos Complementares

A seguir são apresentados os resultados obtidos em cada uma das fases de Estudos Complementares dos algoritmos genéticos seqüências.

6.8.2.1 Fase de Reservatório dos Melhores Cromossomos

O objetivo desta fase é verificar se, partindo de uma população já otimizada, consegue-se um ganho adicional na função objetivo em relação ao encontrado na fase de seleção global, para os algoritmos genéticos seqüenciais. Adicionalmente, deseja-se verificar se o tempo de convergência apresenta redução sensível, quando comparado a uma população inicialmente aleatória. Para tanto, foram adotadas as seguintes decisões:

- Sessões de 10 simulações.
- Foi utilizado o melhor *set* obtido na fase de calibração, ou seja, *set* 6 do algoritmo genético método de seleção por torneio, população de 1000, da fase de seleção global. Este *set* será identificado nessa fase como *set* 01.
- Foi criado um *set* contendo os melhores cromossomos das fases anteriores. Este *set* foi definido como *set* 02.
- Foram levantados dados para a criação de gráficos de demanda em cada um dos setores para o melhor cromossomo encontrado (cenário aeronáutico), pois nesta fase foi encontrado o melhor cenário aeronáutico (função objetivo de maior valor).

O item F.2.1 - Fase de Reserva dos Melhores Cromossomos do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Observou-se que foi obtido um ganho significativo em termos evolutivos (função objetivo), em relação ao melhor algoritmo genético e *set* obtido na fase de seleção global, da etapa de calibração. Uma justificativa seria que a função objetivo, utilizada no modelo de otimização de demanda, fosse uma função multimodal, com diversos picos de máximos locais. Estes máximos locais podem gerar facilmente convergências prematuras, prejudicando a convergência para um máximo global até a fase de seleção global.

Esta técnica de selecionar os melhores cromossomos diminuiu significativamente a diversidade genética e, portanto, aumentou a pressão seletiva, fazendo com que a velocidade de convergência reduzisse-se rapidamente, conforme observado pela sensível redução do tempo de simulação (otimização) desta fase.

Outra possível justificativa pode ser dada pelo fato que, utilizando-se uma população inicial já otimizada (não aleatória) contendo os melhores cromossomos de fases anteriores, esta possua diversos blocos construtivos (*building blocks*) obtidos em otimizações anteriores. Os blocos construtivos são arranjos particulares dentro da cadeia cromossômica que fazem parte da solução ótima, contribuindo, portanto, positivamente na função objetivo (FREGNI, 1997) e (HOLLAND, 2000). A população inicial otimizada pode possuir um grande número de blocos construtivos, em que já foram investidas diversas gerações (tempo de processamento). Adicionalmente, estes diversos blocos construtivos da população inicial podem ser combinados e gerar outros novos blocos construtivos, ainda mais favoráveis, que aumentem o valor da função objetivo.

Nesta fase obteve-se a melhor otimização encontrada nesta pesquisa. Para esta melhor otimização foram traçados os gráficos da demanda otimizada em cada um dos setores da infra-estrutura aeronáutica. O objetivo foi verificar se, em todos os setores, a demanda otimizada obtida encontrava-se abaixo do patamar de saturação aceitável.

A seguir são apresentados os gráficos das demandas de três setores do cenário aeronáutico estudado. Destes três setores, dois estão entre os mais críticos da infra-estrutura aeronáutica estudada, devido à excessiva demanda, e um terceiro setor considerado como intermediário. Os setores mais críticos são apresentados como forma

de avaliar se houve uma redução significativa de carga de trabalho de gerenciamento destes setores, após o processo de otimização. Já o setor intermediário é apresentado de forma a verificar se a otimização chega a ser alcançada, também nestes setores menos críticos.

Para cada diagrama de situação original (não otimizado) está sendo apresentado em conjunto, o diagrama de análise de situação otimizado, com amostragem de 60 segundos.

Setores críticos

Os dois setores críticos selecionados para a plotagem dos diagramas de análise de situação são da área de controle terminal de São Paulo, mais precisamente os setores XP01 e XP03. O diagrama de análise de situação do setor XP01 antes e após a otimização é apresentado na figura 6.3.

Observe que nos gráficos existem 3 linhas horizontais identificando os patamares de congestionamento (80% da capacidade nominal declarada do setor), saturação (100% da capacidade nominal declarada do setor), saturado aceitável (120% da capacidade nominal declarada do setor). Acima do nível de saturação aceitável, o tráfego é considerado supersaturado.

Note que o gráfico de demanda não otimizada apresenta diversos instantes de tempo em que a região supersaturada é ultrapassada. A capacidade máxima nominal deste setor é igual a 8 aeronaves. Pode-se observar que em certos instantes o mesmo chega a apresentar até 14 aeronaves simultâneas. Pode-se considerar este setor como um dos mais crítico em função do valor obtido para a carga de trabalho não otimizada (WL Setor).

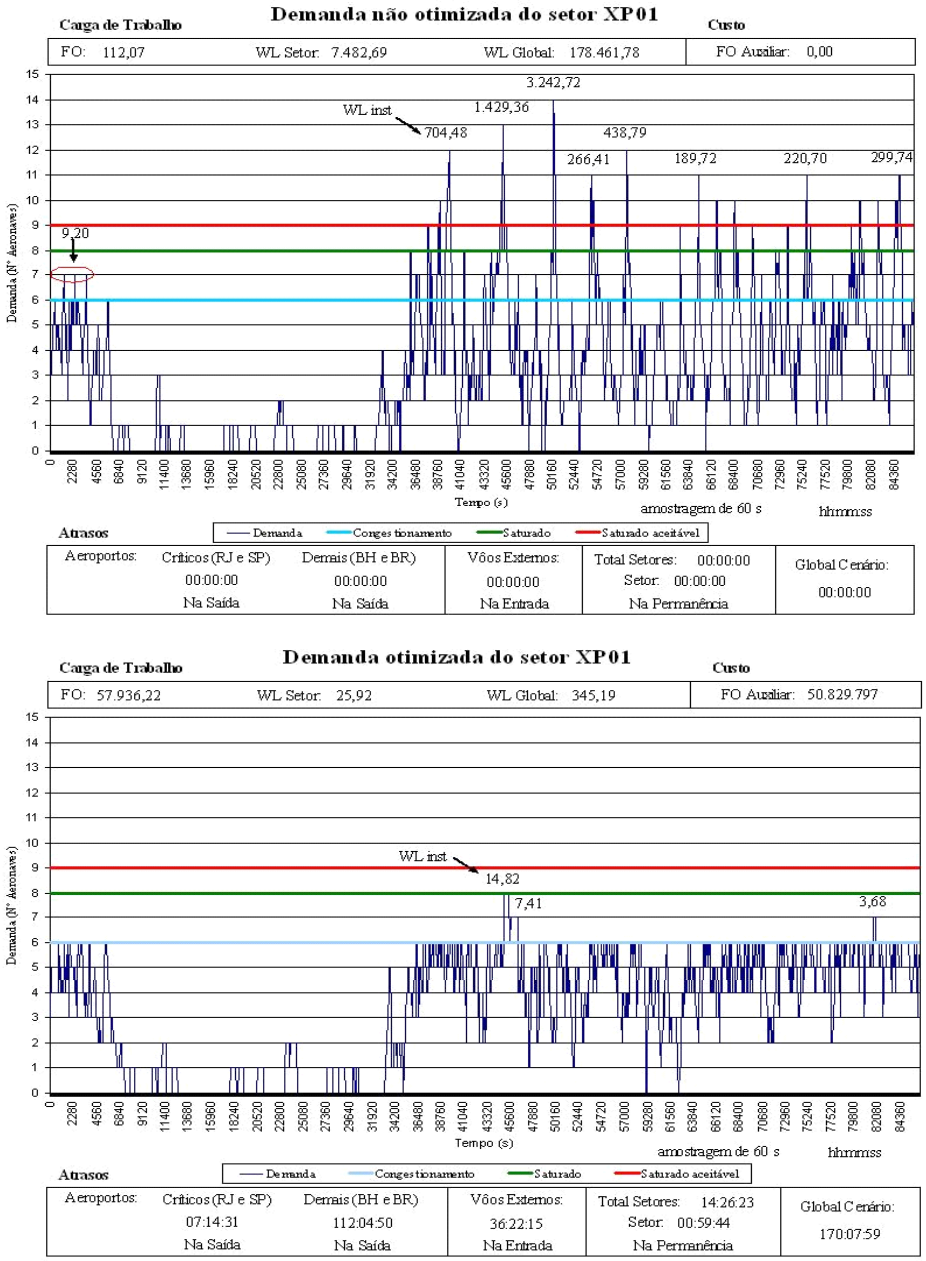

Figura 6.3: Diagramas de análise de situação do setor XP01

Observe, pelo diagrama de análise de situação otimizado, que se conseguiu obter em todos os instantes de tempo uma demanda abaixo da região de supersaturação. Na verdade, este resultado foi alcançado para todos os setores da infra-estrutura aeronáutica, podendo-se afirmar que a otimização de demanda foi efetiva para todo a infra-estrutura aeronáutica do cenário estudado. Este resultado é muito importante, pois mostra que o

modelo de otimização de demanda proposto, utilizado neste cenário crítico do contexto brasileiro, pôde trazer uma redução significativa da demanda e, por conseqüência, da carga de trabalho de gerenciamento global do cenário, preservando os níveis de segurança (*safety*). Assim, o objetivo inicialmente proposto foi alcançado.

Nos diagramas de análise de situação são apresentados além dos gráficos de demanda propriamente ditos, três categorias de informações: carga de trabalho, custo hipotético e atrasos. O custo hipotético é também denominado de função objetivo auxiliar (FO Auxiliar). As legendas dos demais valores são apresentados nas tabelas 6.8 a 6.10.

Carga de Trabalho

Tipo de parâmetro	Definição
Função Objetivo (FO)	utilizada como direcionador do processo de otimização dos algoritmos genéticos.
Carga de trabalho do Setor (WL Setor)	Carga de trabalho de gerenciamento do setor (WL Setor) do diagrama de análise de situação plotado.
Carga de Trabalho instantâneo (WL inst)	Carga de trabalho de gerenciamento de um instante de tempo (WL inst), no qual a demanda ultrapassa o nível de congestionamento.
Carga de trabalho do cenário aeronáutico (WL Global)	Soma da carga de trabalho de todos os setores do cenário aeronáutico em análise.

Tabela 6.8: Parâmetros relacionados a Carga de Trabalho

Custos

Tipo de parâmetro	Definição
Função Objetivo Auxiliar (FO Auxiliar)	Valor de custo hipotético relativo a todos os atrasos gerados pela otimização. Não participa do processo de otimização.

Tabela 6.9: Parâmetro relacionados a Custo

Atrasos

Tipo de parâmetro	Definição
Aeroportos críticos	Atrasos de decolagem (saída) dos vôos nos aeroportos do Rio de Janeiro e São Paulo, em relação ao horário nominal de decolagem da aeronave.
Demais aeroportos	Atrasos de decolagem (saída) dos vôos nos aeroportos de Belo Horizonte e Brasília, em relação ao horário nominal de decolagem (saída) da aeronave.
Vôos externos	Atrasos no tempo de entrada das aeronaves em um dos setores da infra-estrutura aeronáutica analisada, em relação ao horário nominal de entrada, definido para a aeronave.
Setor	Soma dos atrasos (permanência) de todos os vôos no setor da infra-estrutura aeronáutica estudada.
Total dos Setores	Soma dos atrasos (permanência) dos vôos em todos os setores da infra-estrutura aeronáutica.
Global cenário	Atraso global produzido pela otimização para o cenário aeronáutico analisado, ou seja, soma dos atrasos produzidos nos setores, mais os atrasos dos vôos externos, mais os atrasos produzidos nos aeroportos.

Tabela 6.10: Parâmetros relacionados a Atrasos

Na figura 6.4 são apresentados os diagramas de análise de situação antes e após a otimização para o setor XP03 da área de controle terminal de São Paulo.

Os atrasos e o custo hipotético em todos os diagramas de análise de situação original (não otimizada) apresentam valores iguais a zero. Este fato é adotado pois nestes diagramas de análise de situação são considerados apenas os tempos de permanência, tempo de decolagem e entrada de vôos externos nominais, sem qualquer otimização. Estes tempos são considerados ideais, mas **inviáveis** devido a excessiva carga de trabalho de gerenciamento global gerada pelos mesmos.

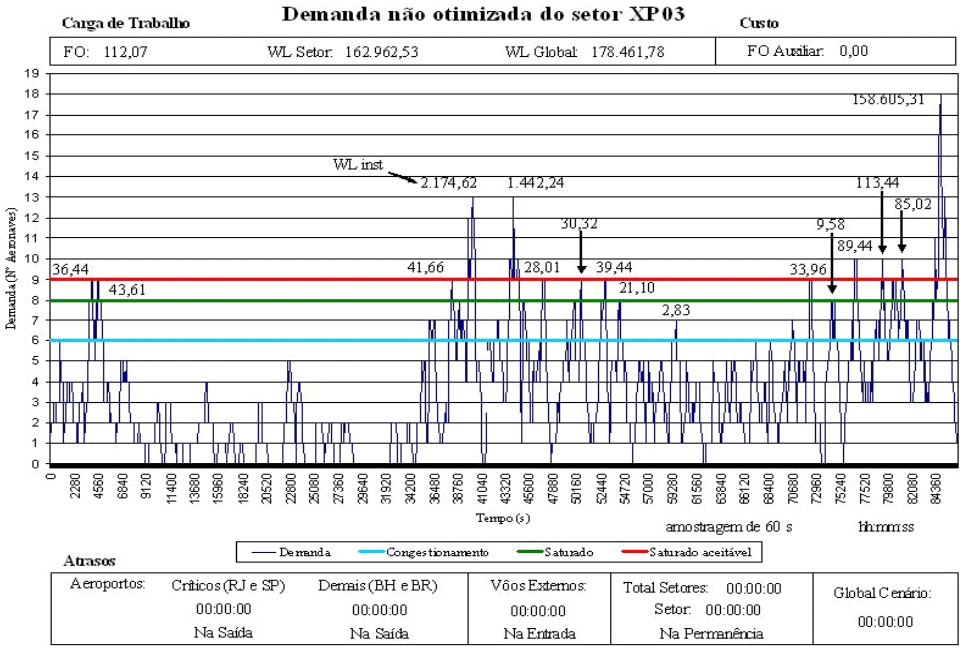

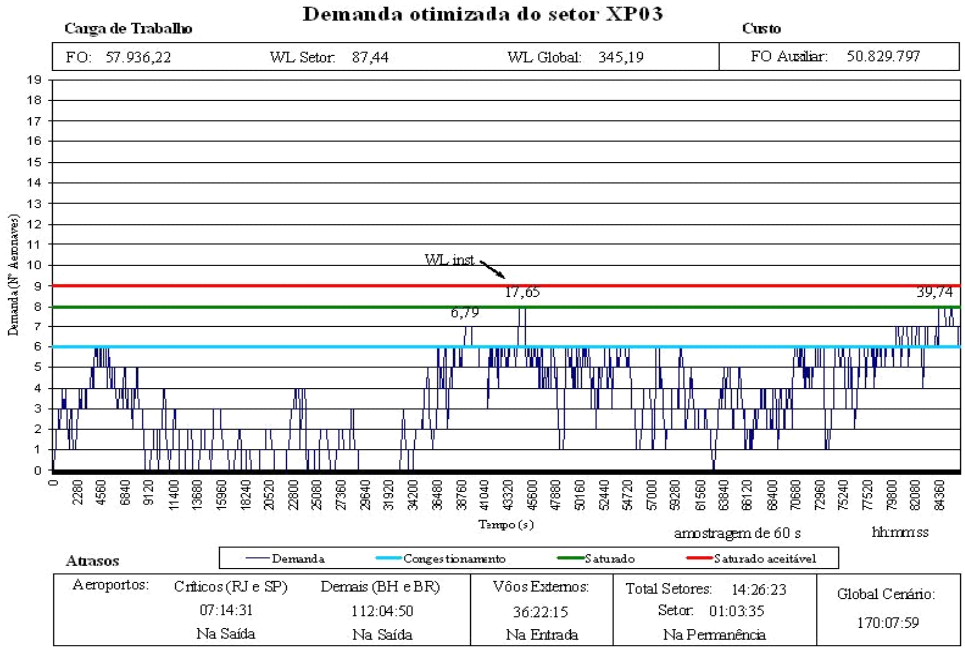

Figura 6.4: Diagramas de análise de situação para o setor XP03

Notou-se que quanto maior a redução da carga de trabalho, maiores são as distribuições dos vôos ao longo do tempo (em relação aos tempos nominais dos vôos). Também são maiores os atrasos gerados dentro de cada setor, em relação ao cenário original, bem como, para o cenário aeronáutico analisado como um todo.

Este fato era esperado pois, a diminuição da carga de trabalho em cada setor, bem como para toda a infra-estrutura aeronáutica, está associada a uma melhor distribuição das aeronaves ao longo do tempo, provocando atrasos em relação ao cenário original. Mas, deve ser lembrado que estes atrasos são gerados de forma controlada, dado pelos limites máximos das janelas de tempo nos aeroportos e setores, definidos inicialmente no modelo de otimização de demanda.

Setores não críticos

O setor não crítico selecionado para a apresentação dos diagramas de análise de situação foi do espaço aérea superior, mais precisamente o setor BS02. O diagrama de análise de situação deste setor antes e após a otimização é apresentado na figura 6.5.

Observou-se que, mesmo para setores em que não há excesso de demanda, também houve uma redução na carga de trabalho. Este efeito é benéfico pois permite que um maior número de vôos possam ser acomodados futuramente na infra-estrutura aeronáutica.

O efeito da redução da carga de trabalho mesmo em setores não críticos está associado ao processo de otimização global do cenário aeronáutico ser realizado como um todo. Este fato pode ser também justificado pela interdependência das rotas sobre os setores da infra-estrutura aeronáutica. Assim, alterar ou modificar o tempo de permanência de uma aeronave em um dado setor, significa também alterar o tempo de permanência da mesma aeronave em todos os setores por onde ela irá passar.

Para a comparação dos diagramas de análise de situação dos demais setores da infra-estrutura aeronáutica, original e otimizados veja o Apêndice H – Melhores Resultados Encontrados para a Otimização.

A grande vantagem do modelo de otimização de demanda é acomodar o tráfego ao longo do tempo, garantindo-se uma carga de trabalho de gerenciamento global dentro de níveis de segurança (*safety*) aceitáveis. Esta distribuição de demanda ao longo do tempo deve ser realizada de forma criteriosa, de tal forma a não permitir que sejam gerados atrasos excessivos, que possam prejudicar de forma expressiva os serviços de transporte aéreo.

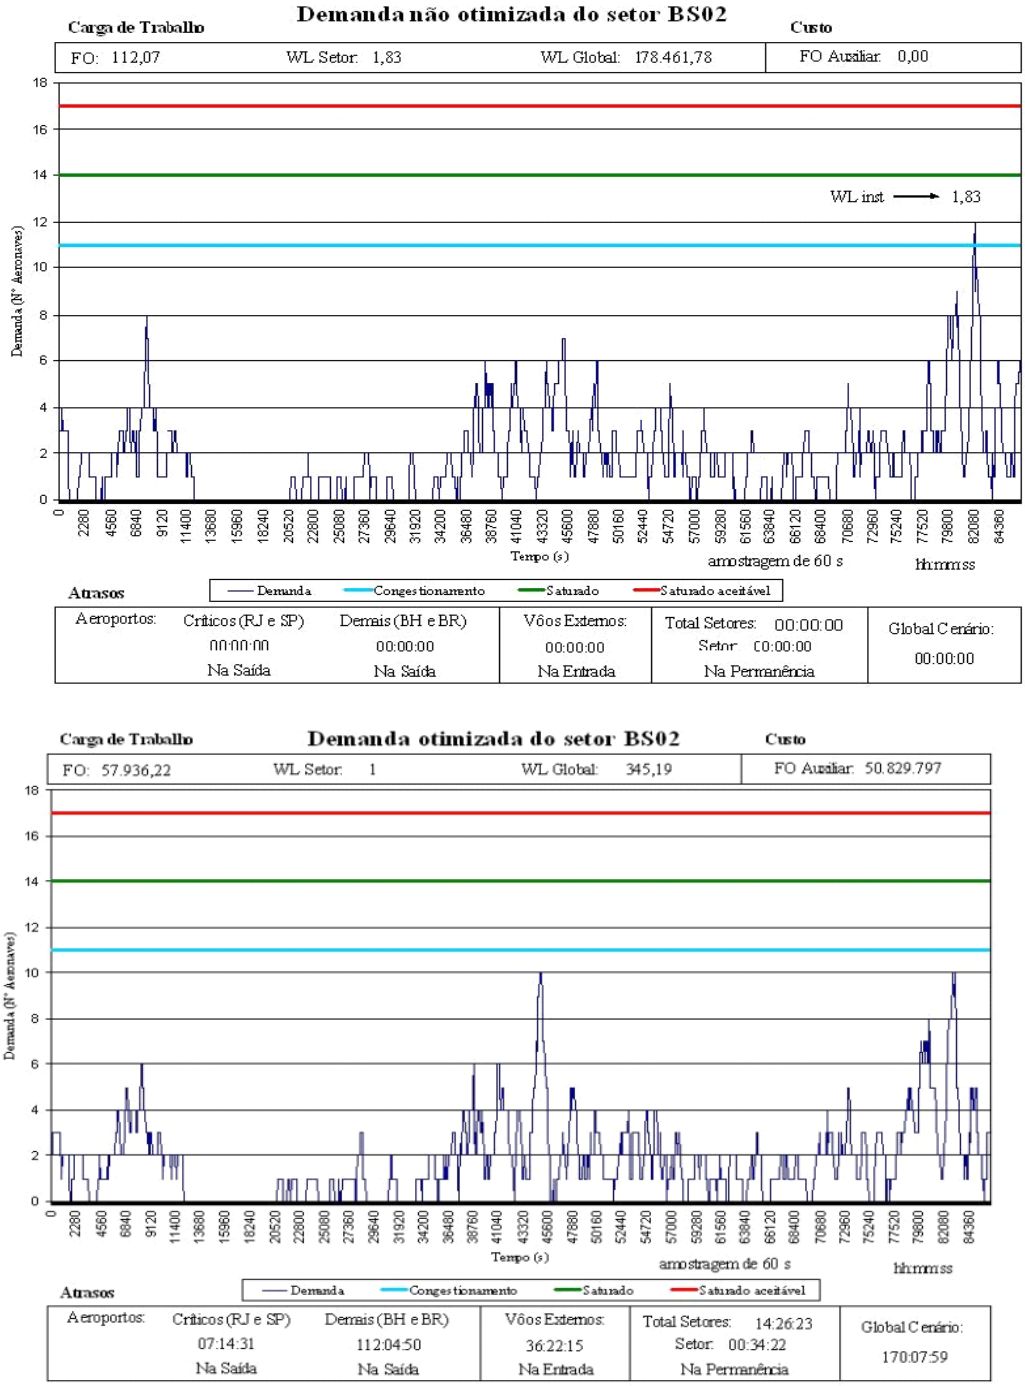

Figura 6.5: Diagramas de análise de situação para o setor BS02

Este fato é dado pelas restrições de atrasos nos aeroportos, tamanhos de janelas de tempo nas áreas terminais e nos espaços aéreos superiores, bem como nos atrasos e adiantamentos de entrada de vôos externos do cenário aeronáutico estudado.

6.8.2.2 Fase de Pequena Alteração da Demanda

O objetivo desta fase é verificar se, para uma pequena variação na demanda futura, mas próxima de uma demanda já otimizada (reservatório de cromossomos), consegue-se reduzir de forma significativa o tempo de otimização para esta nova demanda. Para tanto, nesta fase foram adotadas as seguintes decisões:

- Os dados originais, referentes aos planos de vôos repetitivos (RPL), possuem 1654 vôos, durante 24 horas. A demanda foi alterada em torno de 2%, ou seja, em 33 vôos. A forma adotada para realizar esta alteração foi modificar os horários padrões de decolagem dos vôos nos aeroportos, bem como os horários de entrada dos vôos externos no cenário analisado. Esta alteração é similar à introdução de atrasos nestes vôos.

  Foi atrasado o horário nominal de decolagem de 10 vôos em setores críticos, da seguinte forma: 10 minutos (4 vôos), 15 minutos (3 vôos), 20 minutos (2 vôos) e 30 minutos (1 vôo).

  Foi atrasado também o horário nominal de decolagem de 10 vôos em setores não críticos, da seguinte forma: 20 minutos (4 vôos), 25 minutos (4 vôos), 30 minutos (2 vôos) e 30 minutos (2 vôos).

  Adicionalmente foi alterado o horário de entrada nominal de 13 vôos externos, da seguinte forma: 20 minutos (5 vôos), 25 minutos (4 vôos), 20 minutos (3 vôos) e 25 minutos (1 vôo).

  Vale ressaltar, que foram mantidas as janelas de tempo previamente definidas no cenário aeronáutico.
- Sessões de 10 simulações.
- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração, ou seja, *set* 6 do algoritmo genético método de seleção por torneio, população de 1000 cromossomos, da fase de seleção global.

Foram criados três *sets* descritos a seguir, sendo que em dois deles foram reduzidos o número de gerações de estabilidade do critério de parada. Este critério foi adotado com o objetivo adicional de verificar a influência do número de gerações de estabilidade do critério de parada sobre a otimização final (função objetivo).

Assim, forma criados os seguintes *sets*:

Set 01: valores do *set* referencial utilizando a demanda alterada.

Set 02: valores do *set* 01 alterando-se o primeiro e segundo pontos de estabilidade do critério de parada para 100 e 200 gerações respectivamente.

Set 03: valores do *set* 01 alterando-se o primeiro e segundo pontos de estabilidade do critério de parada para 50 e 100 gerações respectivamente.

O item F.2.2 - Fase de Pequena Alteração de Demanda do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Esperava-se nesta fase uma redução sensível do tempo de otimização devido aos fatos discutidos em (FREGNI, 1997) e destacados a seguir.

Supõe-se que o problema de otimização original e o problema agora apresentado são da mesma família de problemas, dado que foram alterados apenas 2% dos vôos do cenário aeronáutico inicial.

Foram utilizadas populações iniciais já otimizadas para um problema anterior, mas muito próximo do problema agora existente. Portanto, esperava-se que a existência de blocos construtivos a partir da população inicial, também fosse construtiva para o problema futuro, reduzindo sensivelmente o tempo de otimização.

Observou-se na prática que não houve uma redução significativa no tempo de otimização. Uma possível justificativa é que o número de alterações de rotas foi extremamente elevado, mesmo que percentualmente possa ser considerado um valor reduzido. Talvez porcentagens inferiores a 2% possam trazer melhores resultados, com redução significativa do tempo de otimização do algoritmo genético.

Observou-se também que a qualidade da otimização, ou seja, a função objetivo também sofreu grande interferência pela modificação do número de gerações de estabilidade do critério de parada. Quanto menor o número de gerações do critério de parada, menor é a qualidade da otimização. Portanto, a qualidade da solução e, principalmente, a obtenção de cenários aplicáveis na prática, depende de um número mínimo de gerações ao final do processo de otimização, desde que a convergência não fique atrelada a um máximo

local. A grande questão aqui é determinar qual é o número de gerações mínimos a ser utilizado no critério de parada por estabilidade que simultaneamente, encontre o resultado de otimização procurado e não consuma recursos computacionais de forma desnecessária.

O fato de haver redução no tempo de otimização e na qualidade da otimização em função da redução do número de gerações do critério de parada, torna-se importante quando há restrições de tempo para obter um resultado da otimização. Neste caso, a redução do tempo de otimização pode ser mais relevante que a qualidade do resultado obtido. Questão importante a ser destacada, neste caso, é verificar se a redução de tempo de otimização alcançada pela menor rigidez do critério de parada, seja suficiente para gerar cenários eficientes em termos da aplicação.

Um fato interessante é que a melhor otimização, obtida na fase de seleção global nos algoritmos genéticos seqüenciais, com população inicial totalmente aleatória apresentou, em média, um tempo de otimização em torno de 73 hs. Já o mesmo algoritmo genético e *set*, na fase de reservatório dos melhores cromossomos, ou seja, com uma população não aleatória, durou em média 17 hs para otimização. Nessa fase de pequena alteração de demanda, em que também é utilizada uma população inicial não aleatória e otimizada para uma demanda próxima (demanda 2% alterada), consumiu em média 37 hs de otimização. Observou-se que o tempo de otimização da fase de pequena alteração de demanda localiza-se entre os tempo de otimização das duas demais fases estudadas. Provavelmente, se a fase de pequena alteração de demanda tivesse sido iniciada com uma população totalmente aleatória, ter-se-ia um tempo de otimização muito próximo, do tempo de otimização, obtido na fase de seleção global. Assim, pode-se concluir que a adoção de uma população inicial já otimizada para um problema próximo (em que a demanda não seja muito diferente da atual), pode trazer alguma redução no tempo de otimização. Maior será esta redução quanto mais próxima for a demanda futura da atual, bem como, quanto menos rígido for o critério de parada por estabilidade.

6.8.2.3 Fase de Flexibilização do Intervalo de Amostragem

O objetivo desta fase é verificar a influência do intervalo de amostragem no processo de otimização (evolução) dos algoritmos genéticos. Para tanto, nesta fase foram adotadas as seguintes decisões:

- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração, ou seja, o *set* 06 do algoritmo genético método de seleção por torneio, população de 1000 cromossomos, da fase de seleção global.
- Foi utilizado, como referência também, o *set* obtido na fase de reservatório dos melhores cromossomos, ou seja, o *set* 02.
- Sessões de 10 simulações.
- O intervalo de amostragem foi diminuído de 60 para 15 segundos. Anteriormente, foram realizados testes preliminares com intervalos de amostragens de 1, 5 e 10 segundos. Verificou-se que estes intervalos de amostragem eram inviáveis de serem adotados, devido às limitações do ambiente de simulação alcatéia (300 horas).
- Os resultados desta fase foram comparados com os melhores resultados obtidos até o momento, obtidos na fase de reservatório dos melhores cromossomos. Adicionalmente, os resultados desta fase também foram comparados com os melhores resultados da fase de calibração. Em todos eles foram utilizados o *set* 06 do algoritmo genético seleção por torneio, população de 1000 cromossomos. O objetivo é verificar se, com a redução do intervalo de amostragem, obtém-se também redução da carga de trabalho global de gerenciamento, ou seja, maiores valores para função objetivo.

Assim, foram criados os seguintes *sets*:

Set 01: valores da melhor otimização encontrada na etapa de calibração, fase de seleção global.

Set 02: valores da fase de reservatório dos melhores cromossomos.

Set 03: valores da fase de flexibilização do intervalo de amostragem.

O item F.2.3 - Fase de Flexibilização do Intervalo de Amostragem do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Para a fase de flexibilização do intervalo de amostragem pode ser observado que houve uma redução significativa na carga de trabalho global de gerenciamento com intervalos de amostragens menores. Isto se justifica devido ao fato que quanto menor a amostragem, mais precisa está a demanda considerada no processo de otimização da demanda real.

Esta precisão é devido à redução do erro de arredondamento cometido propositalmente para amostragens maiores, de forma a garantir a segurança (*safety*) da carga de trabalho global de gerenciamento da infra-estrutura analisada.

Uma forma de complementar e auxiliar o entendimento do efeito do intervalo de amostragem sobre a demanda analisada é discutida a seguir. Seja dada uma demanda real conforme apresentado na figura 6.6. Observe que quanto mais se reduzir a amostragem, mais próxima será a demanda considerada na otimização da demanda real em estudo. Elas tornam-se iguais para amostragens de 1 segundo, pois está é o valor da base de tempo considerado como ideal no diagrama de análise de situação.

Adicionalmente, pode ser notado o efeito do erro de arredondamento, cometido propositalmente para garantir maior nível de segurança (*safety*) em amostragens maiores.

Na figura 6.6 observe que o valor zero de demanda corresponde ao valor menor ou igual ao congestionamento (80% da capacidade nominal declarada do setor), ou seja, o diagrama de análise de situação representa apenas o excesso de demanda em um setor qualquer.

Observe que, devido ao erro de arredondamento, ocorre um efeito entre os instantes de 300 e 360 segundos. Aproximadamente no instante 300 existe um pico na demanda real, de curta duração, de 5 aeronaves, que depois decresce para 2 aeronaves e volta a crescer para 3 aeronaves em torno do instante 330 segundos. Devido ao efeito de arredondamento este pico é arredondado para 6 aeronaves no intervalo de 300 a 360 segundos, para a amostragem de 60 segundos.

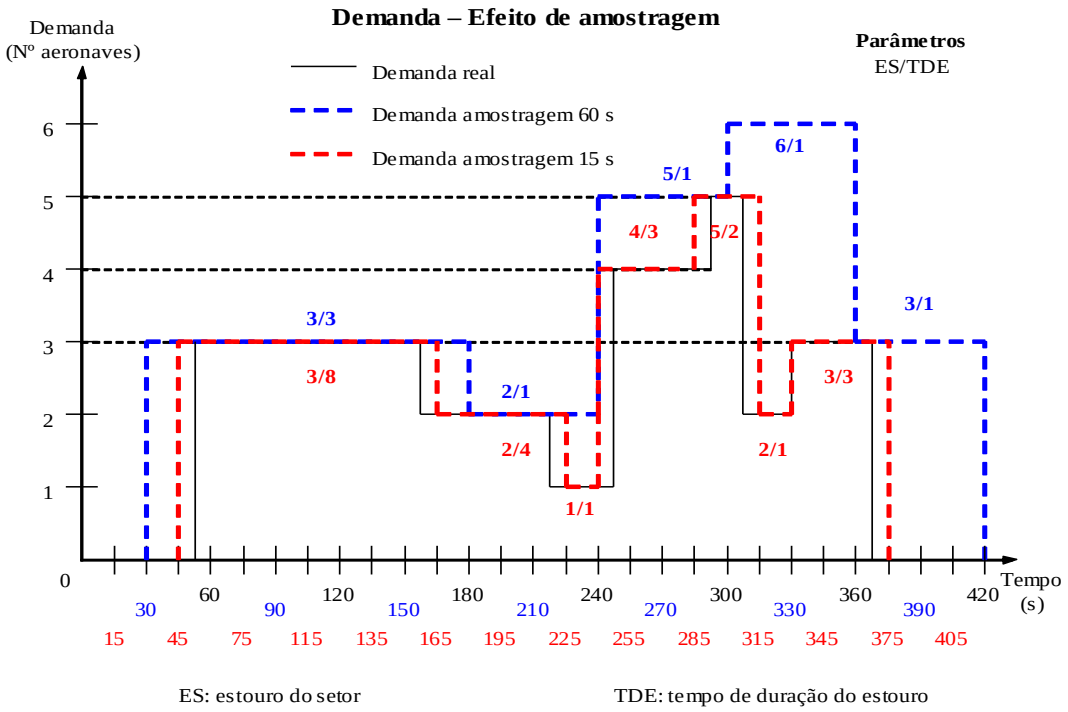

Figura 6.6: Estudo do efeito da amostragem sobre a demanda

Este efeito observado provoca um erro na demanda não prejudicial à segurança (*safety*), pois garante que o número de aeronaves consideradas simultaneamente em cada setor é sempre maior que o realmente existente.

6.8.2.4 Fase de Flexibilização do Intervalo de Discretização

O objetivo desta fase é verificar a influência do intervalo de discretização no processo de otimização (evolução). Para tanto, foram adotadas as seguintes decisões:

- Os intervalos de discretização flexibilizados para 8, 10 e 15 bits.
- *Set* 01: igual ao melhor *set* obtido na etapa de calibração, ou seja, *set* 6 do algoritmo genético método de seleção por torneio, população de 1000 cromossomos, da fase de seleção global.
- *Set* 02: igual ao *set* 01 modificado com intervalo de discretização igual a 8 bits.
- *Set* 03: igual ao *set* 01 modificado com intervalo de discretização igual a 10 bits.
- *Set* 04: igual ao *set* 01 modificado com intervalo discretização igual a 15 bits.
- Sessões de 10 simulações.
- Set 05: igual ao *set* 04 aumentando-se os pontos de mutação de 5 para 10 pontos.

O item F.2.4 - Fase de Flexibilização do Intervalo de Discretização do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Para a fase de flexibilização do intervalo de discretização foi observado que o aumento do número de bits de discretização influi na convergência dos algoritmos genéticos.

Fato interessante observado foi que quanto maior o número de bits de discretização, menor o valor final da função objetivo. Este fato mostra que há um efeito adicional que influência a otimização da carga de trabalho global de gerenciamento, em função do número de bits de discretização.

Uma possível justificativa é que, com o aumento do número de bits, os passos (tamanho efetivo do intervalo de discretização) em cada janela de tempo que podem ser testados, durante a otimização tornam-se menores.

Como o espaço amostral, bem como a função que representa o problema de otimização de demanda são desconhecidos, a função objetivo poderá apresentar diversos máximos locais, ou seja, ser uma função multimodal. Assim, com a diminuição do tamanho de cada passo, pode ocorrer que a otimização fique "presa" em um destes máximos locais com maior probabilidade.

Neste caso, uma possível solução foi aumentar ainda mais o número de pontos de mutação de 5 para 10, fato esse confirmado através dos resultados obtidos nas simulações.

6.8.3 Etapa de Avaliação do Modelo de Otimização de Demanda

A seguir são apresentados os resultados obtidos em cada uma das fases de estudo da etapa de Avaliação do Modelo de Otimização de Demanda.

6.8.3.1 Fase de Análise dos Parâmetros do Modelo

O objetivo desta fase é analisar a influência de cada um dos parâmetros do modelo sobre a carga de trabalho de gerenciamento global do cenário aeronáutico. Adicionalmente, é verificada a possibilidade de aplicação de janelas de tempo somente em aeroportos críticos e demais aeroportos.

A análise desta fase foi realizada em três subanálises, conforme descritas a seguir:

a) Influência de cada parâmetro pela sua inserção no modelo

Análise comparativa de *sets* em que é considerada isoladamente cada uma das janelas no modelo de otimização de demanda. O objetivo é verificar qual a influência de cada uma das janelas de tempo sobre a carga de trabalho de gerenciamento global do cenário aeronáutico em análise. Adicionalmente, procurou-se identificar quais parâmetros do modelo de otimização apresentam maior ou menor influência sobre a carga de trabalho de gerenciamento global.

b) Influência de cada parâmetro pela sua retirada do modelo

Análise comparativa de *sets* em que cada uma das janelas são retiradas (zeradas) do modelo de otimização de demanda, verificando quais delas apresentam maior ou menor influência sobre a carga de trabalho de gerenciamento global. A diferença básica em relação à análise anterior é que nesta fase são considerados vários parâmetros ou janelas de tempo simultaneamente, sendo retirada apenas uma janela de tempo de cada vez, e verificada a influência de sua ausência sobre a carga de trabalho de gerenciamento global.

c) Análise de janelas somente em aeroportos críticos e demais aeroportos

Análise comparativa de diferentes opções de flexibilizações de janelas (atrasos) nos aeroportos críticos e demais aeroportos, considerando as demais janelas de tempo nulas (como não existissem no modelo de otimização), e verificando a influência sobre a carga de trabalho de gerenciamento global.

A estratégia adota foi considerar somente as janelas de tempo dos aeroportos críticos e demais aeroportos, com o objetivo de verificar a influência destas duas janelas sobre a carga de trabalho de gerenciamento global. Estas janelas de tempo apresentam menor impacto sobre o consumo de combustível pelas aeronaves.

- Sessões de 10 simulações.
- Foi utilizado o melhor *set* obtido na etapa de calibração dos algoritmos genéticos seqüenciais, ou seja, *set* 6 do algoritmo genético método de seleção por torneio, população de 1000, da fase de seleção global.

A tabela 6.11 apresenta os *sets* definidos para esta fase.

Set	Algorit. Genét.	Popul.	*Set* Calib.	Atrasos Aeropor. Críticos SP e RJ	Atrasos em demais Aeroportos	Atraso/ Adiantamento de entrada de vôos	Atraso em Janela de tempo em Área de Controle Terminal	Atraso em Janela de tempo em Espaço Aéreo Superior
Influência de cada parâmetro pela sua inserção no modelo								
1	Torneio	1000	*set* 06	5 min.	-	-	-	-
2	Torneio	1000	*set* 06	-	15 min.	-	-	-
3	Torneio	1000	*set* 06	-	-	15 min. antes, 15 min. depois	-	-
4	Torneio	1000	*set* 06	-	-	-	3% antes, 5 % depois	-
5	Torneio	1000	*set* 06	-	-	-	-	5% antes, 5 % depois
Influência de cada parâmetro pela sua retirada do modelo								
6	Torneio	1000	*set* 06	5 min.	15 min.	-	3% antes, 5 % depois	5% antes, 5 % depois
7	Torneio	1000	*set* 06	5 min.	15 min.	15 min. Antes, 15 min depois	-	5% antes, 5 % depois
8	Torneio	1000	*set* 06	5 min.	15 min.	15 min. Antes, 15 min depois	3% antes, 5 % depois	-
9	Torneio	1000	*set* 06	5 min.	-	15 min. Antes, 15 min depois	3% antes, 5 % depois	5% antes, 5 % depois
10	Torneio	1000	*set* 06	-	15 min.	15 min. Antes, 15 min depois	3% antes, 5 % depois	5% antes, 5 % depois
Análise de janelas somente em aeroportos críticos e demais aeroportos								
11	Torneio	1000	*set* 06	10 min.	15 min.	-	-	-
12	Torneio	1000	*set* 06	5 min.	20 min.	-	-	-
13	Torneio	1000	*set* 06	10 min.	20 min.	-	-	-

Tabela 6.11: *Sets* para análise de parâmetros - continuação

Quando não estão apresentados os valores dos parâmetros na tabela 6.11, significa que estes parâmetros (janelas de tempo) não existem, ou seja, não estão sendo considerados no correspondente *set*.

O item F.3.1 - Fase de Análise dos Parâmetros do Modelo do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Para esta fase podem ser feitos os seguintes comentários e conclusões para cada uma das subfases estudadas:

a) Influência de cada parâmetro pela sua inserção no modelo

Pelo teste de hipótese observou-se que os atrasos nos demais aeroportos apresentaram a maior influência na carga de trabalho global de gerenciamento do cenário aeronáutico. Em contrapartida, os atrasos em aeroportos críticos apresentaram a menor influência na carga de trabalho global de gerenciamento. A classificação a seguir, obtida através dos testes de hipótese desta fase, apresenta a influência de forma decrescente, dos parâmetros do modelo de otimização, sobre a carga de trabalho global de gerenciamento do cenário aeronáutico estudo:

1 - Atrasos em demais aeroportos

2 - Atrasos e adiantamentos de entrada dos vôos externos

3 - Janelas de tempo em áreas de controle terminal

4 - Janela de tempo no espaço aéreo superior

5 - Atrasos em aeroportos críticos

Vale observar que os atrasos nos demais aeroportos e os atrasos e adiantamento da entrada dos vôos externos podem ser considerados como os parâmetros que apresentaram a maior influência na carga de trabalho global de gerenciamento.

Um fato que contribui para a classificação está relacionado ao tamanho da janela de tempo adotado para cada parâmetro do modelo de otimização. Vale observar que os atrasos e adiantamentos dos vôos externos apresentaram o maior tamanho de janela de tempo, e os atrasos nos demais aeroportos a segunda maior janela de tempo adotada. Em contraposição, os atrasos em aeroportos críticos apresentam uma das menores janelas de tempo, em conjunto com as janelas de tempo dos setores das áreas de controle terminal e espaço aéreo superior.

É importante observar este fato pois os tamanhos das janelas de tempo interferem diretamente na classificação apresentada. Estas janelas de tempo foram definidas inicialmente para o modelo de otimização de demanda, em função de critérios de criticidade dos diversos elementos da infra-estrutura aeronáutica e da relação com os

custos associadas às janelas de tempo em vôo (de áreas de controle terminais e espaço aéreo superior). Se fossem definidos outros tamanhos de janelas de tempo, ou então, se todas as janelas fossem do mesmo tamanho, provavelmente a classificação apresentada seria diferente.

b) Influência de cada parâmetro pela sua retirada do modelo

Pelos testes de hipótese pôde-se obter a classificação a seguir, que apresenta a ordem decrescente de influência dos parâmetros do modelo de otimização, sobre a carga de trabalho global de gerenciamento:

1 - Atrasos em demais aeroportos

2 - Atrasos e adiantamentos de entrada dos vôos externos

3 - Janelas de tempo em áreas de controle terminal

4 - Atrasos em aeroportos críticos

5 - Janela de tempo no espaço aéreo superior

Observe que houve uma inversão na ordem de classificação dos dois últimos parâmetros. Esta inversão na classificação pode ser justificada pelos tipos de testes realizados.

A conclusão efetiva, em relação aos dois testes realizados, é que tanto os atrasos nos demais aeroportos, quanto os atrasos e adiantamentos de entrada dos vôos externos, apresentam, aparentemente, maior influência na carga de trabalho global de gerenciamento em relação aos demais parâmetros.

Estes resultados são válidos somente em relação aos parâmetros do modelo de otimização adotados e, principalmente, ao tamanho de janela de tempo a eles associados à priori. Se forem adicionados outros parâmetros ao modelo de otimização de demanda, bem como, alteradas as janelas de tempo dos mesmos, os resultados apresentados podem ser bastante diferentes.

Estes resultados são relevantes na medida que podem dar indício de quais parâmetros apresentam os melhores e piores resultados em termos de flexibilização, com o objetivo de reduzir ainda mais a carga de trabalho de gerenciamento global do cenário aeronáutico. Em conjunto podem ser realizadas análises de planejamento, de forma a encontrar quais parâmetros apresentam menor interferência, tanto no fluxo de tráfego

aéreo, quanto nos serviços de transporte aéreo. Este tipo de análise permite analisar o fluxo de tráfego aéreo em futuras expansões da infra-estrutura aeronáutica.

É possível também realizar análises de impacto na infra-estrutura aeronáutica atual com projeções de demanda futuras de tráfego aéreo. Este tipo de análise pode permitir um melhor planejamento, tanto de necessidades futuras, quanto de possíveis soluções para necessidades atuais da infra-estrutura aeronáutica existente.

c) Análise de janelas somente em aeroportos críticos e demais aeroportos

Observou-se que a flexibilização nas janelas de tempo dos aeroportos críticos e demais aeroportos pode ser insuficiente para produzir uma redução significativa na carga de trabalho global de gerenciamento. Este fato leva a concluir que pode ser interessante considerar diversas flexibilizações simultâneas dos parâmetros do modelo para se obter uma maior influência na carga de trabalho global de gerenciamento do cenário aeronáutico.

6.8.3.2 Fase de Flexibilização do Modelo

O objetivo da fase de flexibilização do modelo é verificar a influência da flexibilização dos parâmetros do modelo (janelas de tempo), sobre a carga de trabalho de gerenciamento global.

As flexibilizações de parâmetros permitirão, segundo uma visão de apoio à decisão (visão de planejamento), alternativas de forma a diminuir ainda mais o excesso de demanda em setores críticos.

Adicionalmente, também permitirá avaliar a influência de cada um dos parâmetros do modelo, sobre o processo de otimização e da diminuição de carga de trabalho de gerenciamento em cada um dos setores gerenciados.

As seguintes flexibilizações de parâmetros foram realizadas:

- Tempos de permanência em aeroportos:
  - Aeroportos mais congestionados (SP e RJ): atrasos em decolagem fixados em 5 minutos (janela nominal). A janela neste caso seria flexibilizada para 10, 15, 20 e 30 minutos, ou seja, ter-se-ia neste caso maiores atrasos no horário de decolagem das aeronaves.

- Demais aeroportos: atrasos em decolagem fixados em 15 minutos (janela nominal). A janela neste caso seria flexibilizada para 20 e 30 minutos.

- Tempos de entrada no cenário aeronáutico em análise:
  - Os vôos foram fixados em 15 minutos para atrasos e adiantamentos de entrada no cenário aeronáutico em análise. A flexibilização seria neste caso para entradas de 20 e 30 minutos antes e depois do horário definido para entrada em setores do espaço aéreo superior.
- Janelas de Tempo:
  - Áreas Terminais: a janelas foram fixadas em 3% antes até 5% depois do tempo de permanência nominal para cada uma das aeronaves, em cada setor do cenário aeronáutico analisado. A flexibilização permitiu as janelas variarem desde 6% antes, até 10% depois.
  - Setores do espaço aéreo superior: a janelas foram fixadas em 5% antes até 5% depois do tempo de permanência nominal para cada uma das aeronaves, em cada setor do cenário aeronáutico analisado. A flexibilização permitiu as janelas variarem desde 10% antes até 10% depois.
- Variação simultânea de vários parâmetros e verificação do efeito desta variação sobre a função objetivo.
- Sessões de 10 simulações.
- Foi utilizado o melhor *set* obtido na fase de calibração dos algoritmos genéticos seqüenciais, ou seja, *set* 06 do algoritmo genético método de seleção por torneio, população de 1000.

As tabelas 6.12 e 6.13 apresentam os *sets* definidos para cada uma das flexibilizações adotadas nesta fase.

O item F.3.2 - Fase de Flexibilização do Modelo do Apêndice F – Testes de Hipótese para os Algoritmos Genéticos Seqüenciais, apresenta os resultados dos testes de hipótese desta fase.

A análise da fase de flexibilização do modelo pode ser realizada em várias subanálises, verificando diversos aspectos em função da flexibilização dos parâmetros do modelo de

otimização de demanda. Basicamente, a análise adotada dos parâmetros foi em função dos itens, conforme a tabela 6.14.

Flexibilizações isoladas	
Atrasos em aeroportos críticos	
Set	**Flexibilização**
01	10 minutos
02	15 minutos.
03	20 minutos
04	30 minutos
Atrasos em demais aeroportos	
Set	**Flexibilização**
05	20 minutos
06	30 minutos
Atrasos e adiantamentos de entrada de vôos externos no cenário aeronáutico	
Set	**Flexibilização**
07	20 min. antes, 20 min depois
08	30 min. Antes,30 min. Depois
Janela em área de controle terminal	
Set	**Flexibilização**
09	6% antes, 10% depois
Janela em espaço aéreo superior	
Set	**Flexibilização**
10	10% antes, 10% depois

Tabela 6.12: *Sets* com flexibilizações isoladas dos parâmetros

Flexibilizações simultâneas					
Set	**Atrasos aeroportos críticos**	**Atrasos em demais aeroportos**	**Atraso e adiantamento de entrada de vôos externos no cenário aeronáutico**	**Atrasos em janelas área de controle terminal**	**Atrasos em janelas espaço aéreo superior**
11	10 min.	20 min.	-	-	-
12	10 min.	20 min.	20 min. antes, 20 min depois	-	-
13	10 min.	20 min.	20 min. antes, 20 min depois	6% antes, 10% depois	10% antes, 10% depois
14	20 min.	30 min.	30 min antes, 30 min. Depois	-	-
15	30 min.	30 min.	30 min antes, 30 min. Depois	-	-
16	30 min.	30 min.	30 min antes, 30 min. Depois	6% antes, 10% depois	10% antes, 10% depois

Tabela 6.13: *Sets* com flexibilizações simultâneas dos parâmetros

Para as janelas de tempo sem valores na tabela 6.13, estão sendo considerados os valores inicialmente adotados para o modelo de otimização de demanda.

Casos de flexilizações analisadas	
Caso	**Flexibilização considerada em um parâmetro**
a) Aeroportos Críticos	Análise comparativa das diferentes flexibilizações de atrasos em aeroportos críticos, verificando a influência desta flexibilização sobre a carga de trabalho de gerenciamento global do cenário aeronáutico estudado (função objetivo).

Tabela 6.14: Diversos casos de flexibilização analisados

Caso	Flexibilização considerada em um parâmetro
b) Demais aeroportos	Análise comparativa das diferentes flexibilizações de atrasos nos demais aeroportos, verificando a influência desta flexibilização sobre a carga de trabalho de gerenciamento global.
c) Vôos externos	Análise comparativa das diferentes flexibilizações de atrasos e adiantamentos de entrada de vôos externos no cenário aeronáutico, sobre a carga de trabalho de gerenciamento global.
d) Janelas de tempo em vôo	Análise comparativa das diferentes flexibilizações de janelas de tempo em áreas de controle terminal e espaço aéreo superior, sobre a carga de trabalho de gerenciamento global.
e) Aeroportos críticos e demais aeroportos	Análise comparativa da flexibilização de 5 minutos adicionais nos aeroportos críticos e demais aeroportos, sobre a carga de trabalho de gerenciamento global.
f) Aeroportos críticos, demais aeroportos e atrasos e adiantamentos de entrada de vôos externos	Análise comparativa da flexibilização de 5 minutos adicionais nos aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos ao cenário aeronáutico, sobre a carga de trabalho de gerenciamento global.
g) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e janelas de tempo em áreas de controle terminal	Análise comparativa da flexibilização de 5 minutos adicionais nos aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e dobrando-se o tamanho das janelas de tempo em áreas de controle terminal.

Tabela 6.14: Diversos casos de flexibilização analisados – continuação

Caso	Flexibilização considerada em um parâmetro
h) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e janelas de tempo em vôo	Análise comparativa da flexibilização de 5 minutos adicionais nos aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada vôos externos e dobrando-se o tamanho das janelas em áreas de controle terminal e espaço aéreo superior.
Caso	**Flexibilização considerada em mais de um parâmetro**
i) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos (mais de um parâmetro).	Análise comparativa da flexibilização de 5 minutos adicionais em aeroportos críticos, demais aeroportos e adiantamento de entrada de vôos externos.
j) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e janelas de tempo em vôo (mais de um parâmetro).	Análise comparativa da flexibilização de 5 minutos adicionais nos aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e dobrando-se as janelas de tempo em áreas de controle terminal e espaço aéreo superior.
k) Flexibilização adicional em aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos (mais de um parâmetro).	Análise comparativa de flexibilização de 5 minutos adicionais nos aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos e dobrando-se as janelas de tempo em áreas de controle terminal e espaço aéreo superior, com relação a flexibilizações adicionais de 15 e 25 minutos em aeroportos críticos e de 15 minutos adicionais em demais aeroportos e, atrasos e adiantamentos de entrada de vôos externos.

Tabela 6.14: Diversos casos de flexibilização analisados - continuação

Caso	Flexibilização considerada em mais de um parâmetro
l) Diferentes flexibilizações simultâneas (mais de um parâmetro).	Análise comparativa de diferentes flexibilizações simultâneas dos diversos parâmetros do modelo de otimização de demanda.
m) Análise geral	Análise comparativa de todas as diferentes flexibilizações estudadas na fase de flexibilização do modelo, sobre a carga de trabalho de gerenciamento global.

Tabela 6.14: Diversos casos de flexibilização analisados - continuação

Análises e comentários desta fase

Para esta fase podem ser feitos os seguintes comentários e conclusões para cada uma das subanálises estudadas:

a) Aeroportos Críticos

Sets utilizados: 1, 2, 3 e 4.

Observou-se que aumentando os atrasos nos aeroportos críticos diminui-se a carga de trabalho global de gerenciamento do cenário aeronáutico estudado.

b) Demais aeroportos

Sets utilizados: 5 e 6.

Observou-se que aumentando os atrasos nos demais aeroportos diminui-se a carga de trabalho global de gerenciamento no cenário aeronáutico estudado.

c) Vôos externos

Sets utilizados: 7 e 8.

Observou-se que aumentando os atrasos e adiantamentos de entrada dos vôos externos no cenário aeronáutico, diminui-se a carga de trabalho global de gerenciamento do cenário.

d) Janelas de tempo em vôo

Sets utilizados: 9 e 10.

O aumento das janelas de tempo em áreas terminais fornece uma maior redução da carga de trabalho global de gerenciamento, em relação ao aumento das janelas de tempo do espaço aéreo superior.

e) Aeroportos críticos e demais aeroportos

Sets utilizados: 1 e 5.

Observou-se que há uma maior redução da carga de trabalho global de gerenciamento com o aumento de 5 minutos nos atrasos nos demais aeroportos do que em relação ao aumento de 5 minutos nos atrasos em aeroportos críticos. Este fato mostrou que o aumento (flexibilização) dos atrasos em demais aeroportos (não críticos) apresenta maior influência na redução de carga de trabalho global de gerenciamento do cenário aeronáutico. Mas deve ser lembrado que esta conclusão deve ser considerada a partir da do tamanho das janelas de tempo definidas inicialmente adotadas para os aeroportos críticos e demais aeroportos, que apresentam valores respectivamente de 5 e 15 minutos. Fato observado e válido, de uma forma geral, quanto ao modelo de otimização de demanda em infra-estrutura aeronáutica, é que quanto maior a janela de tempo de um parâmetro, maior deverá ser a sua influência sobre a carga de trabalho de gerenciamento global do cenário. Assim, se ambas as janelas fossem do mesmo tamanho e tivessem a mesma flexibilização de 5 minutos, os resultados das simulações poderiam ser diferentes do obtido.

f) Aeroportos críticos, demais aeroportos e atrasos e adiantamentos de entrada dos vôos externos

Sets utilizados: 1, 5 e 7.

Observou-se que tem-se maior efeito aumentar em 5 minutos os atrasos e adiantamentos de entrada dos vôos externos no cenário aeronáutico, ou então, nos demais aeroportos, do que aumentar os atrasos em 5 minutos nos aeroportos críticos. Este fato é importante, pois estas medidas de flexibilização nos demais aeroportos e de entrada de vôos externos penalizam menos os vôos e serviços de transporte, bem como o gerenciamento de tráfego aéreo em áreas críticas, tais como, nos aeroportos e áreas de controle terminais de São Paulo e Rio de Janeiro.

Deve ser lembrado também que estas conclusões foram observadas, a partir da flexibilização das janelas de tempo, definidas inicialmente para o modelo de otimização de demanda em infra-estrutura aeronáutica.

g) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos e janelas de tempo em áreas de controle terminal

Sets utilizados: 1, 5, 7 e 9.

Para o aumento em 5 minutos nos atrasos nos demais aeroportos, nos atrasos e adiantamentos de entrada dos vôos externos e dobrando-se as janelas de tempo em áreas de controle terminais, apresentaram, a princípio, reduções equivalentes de carga de trabalho de gerenciamento. Este fato foi observado através dos testes de hipótese realizados. O aumento em 5 minutos nos atrasos e adiantamentos de entrada dos vôos externos pode ser a melhor opção neste caso, por apresentar menor interferência no tráfego interno ao cenário aeronáutico em estudo. O problema desta alternativa reside no menor controle sobre estes vôos externos, dado que os mesmos estão, muitas vezes, sobre jurisprudência de outros países.

A opção em aumentar as janelas de tempo em áreas de controle terminal é a pior alternativa de flexibilização, pois pode envolver maior variação no tempo de permanência dos vôos nos setores, ou seja, provocar maior variação na velocidade das aeronaves. Este fato provoca o efeito de aceleração e desaceleração das mesmas que, por conseqüência, aumenta o consumo de combustível, gerando maiores gastos financeiros para as companhias aéreas. A opção de aumentar em 5 minutos os atrasos em aeroportos críticos apresentou a menor redução de carga de trabalho de gerenciamento. Este fato é importante, pois conforme comentado, estas áreas já são bastante críticas em função do elevado tráfego aéreo e a flexibilização das janelas de tempo das mesmas poderá comprometer ainda mais, à situação críticas destes setores.

Para maior precisão dos resultados obtidos poderão ser realizadas sessões maiores que 10, para procurar distinguir os *sets* observados como equivalentes.

h) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos e janelas de tempo em vôo

Sets utilizados: 1, 5, 7, 9 e 10.

Verificou-se novamente que o aumento em 5 minutos nos atrasos em aeroportos não críticos, atrasos e adiantamentos de entrada dos vôos externos e janelas em áreas de controle terminal continua, a princípio, com a maior redução da carga de trabalho global

de gerenciamento. Aumento das janelas de tempo em espaço aéreo superior é a pior opção, ou seja, apresenta a menor redução de carga de trabalho de gerenciamento. A segunda pior opção é o aumento dos atrasos em aeroportos críticos em 5 minutos. O aumento das janelas em áreas terminais apresentou resultado intermediário entre as opções para a redução da carga de trabalho global de gerenciamento. Este fato é importante, pois estas opções podem ser as menos indicadas, devido respectivamente ao elevado tráfego aéreo, e o consumo excessivo de combustível pelas aeronaves, para a operacionalização destas opções.

i) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos (mais de um parâmetro)

Sets utilizados: 11 e 12.

Observou-se que a flexibilização em 5 minutos simultaneamente nos aeroportos críticos e demais aeroportos, e adicionalmente também ocorre a flexibilização em 5 minutos nos atrasos e adiantamentos de entrada dos vôos externos, produz uma redução de carga de trabalho global de gerenciamento ainda mais significativa.

j) Aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos e janelas de tempo em vôo (mais de um parâmetro)

Sets utilizados: 11, 12 e 13.

Observou-se que a flexibilização simultânea dos atrasos em aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada dos vôos externos em 5 minutos, e dobrando-se as janelas de tempo em áreas de controle terminais e espaço aéreo superior, apresentaram uma redução ainda maior na carga de trabalho global de gerenciamento. Este fato mostra que, de um forma geral, quanto maior o número de parâmetros flexibilizados simultaneamente, maior a redução da carga de trabalho de gerenciamento global do cenário analisado.

k) Flexibilização adicional em aeroportos críticos, demais aeroportos, atrasos e adiantamentos de entrada de vôos externos (mais de um parâmetro)

Sets utilizados: 13, 14 e 15.

Observou-se que flexibilizações adicionais simultâneas em aeroportos críticos, nos demais aeroportos e nos atrasos e adiantamentos de entrada de vôos externos,

apresentaram maior redução da carga de trabalho global de gerenciamento do cenário aeronáutico. Esta comparação foi realizada em relação ao melhor resultado do item anterior (*set* 13).

Este resultado é importante pois em situações críticas, de elevada demanda de tráfego aéreo, a opção de flexibilizações adicionais nos atrasos em aeroportos, demais aeroportos e nos atrasos e adiantamento de entrada dos vôos externos, podem ser preferencial, em relação à flexibilizações menores nestes parâmetros em conjunto com flexibilizações em janelas de tempo em áreas de controle terminal e espaço aéreo superior.

l) Diferentes flexibilizações simultâneas (mais de um parâmetro)

Sets utilizados: 11, 12, 13, 14, 15 e 16.

Observou-se que quanto maior o número de flexibilizações simultâneas das janelas de tempo, maior a redução da carga de trabalho de gerenciamento global do cenário aeronáutico. Adicionalmente, quanto maior a flexibilização (tamanho) de cada janela de tempo, simultaneamente com a flexibilização de outras janelas de tempo, ainda maior é a redução de carga de trabalho global de gerenciamento do cenário aeronáutico.

m) Análise Geral

Sets utilizados: 1 a 16.

De uma forma geral todos os parâmetros apresentaram influência na redução da carga de trabalho global de gerenciamento. As maiores flexibilizações simultâneas de todos os parâmetros trouxeram a maior redução de carga de trabalho global de gerenciamento. Podem existir casos em que a flexibilização individual e crescente de uma única janela de tempo, em solo ou em vôo, já seja suficiente para uma redução desejada da carga de trabalho global de gerenciamento. Esta característica é válida desde que esta flexibilização e sua magnitude possam ser realizadas de forma a não trazer problemas significativos ao fluxo de tráfego aéreo.

Em outras situações a flexibilização simultânea de mais de uma janela de tempo pode ser mais interessante, ou então, trazer melhores resultados que a flexibilização de uma janela individualmente. Na verdade, deve-se analisar caso a caso quais parâmetros podem ser flexibilizados e em qual magnitude. Este tipo de análise, através do modelo

de otimização de demanda, é mais aconselhável em situações de planejamento estratégico.

6.9 Resultados da Calibração dos Algoritmos Genéticos Paralelos

A seguir são apresentados os resultados obtidos em cada uma das etapas de calibração dos algoritmos genéticos paralelos.

6.9.1 Etapa de Calibração

Para a implantação desta calibração foi paralelisado o melhor *set* de cada algoritmo genético seqüencial estudado para a população de 250 cromossomos. O ideal seria a adoção de populações de tamanho igual a 1000, por apresentam maiores valores da função objetivo. No entanto, foi adotado o tamanho de 250 cromossomos devido ao elevado consumo de recursos computacionais necessários para os algoritmos genéticos paralelos, bem como de tempo de processamento para populações de tamanho igual a 1000 cromossomos. Estes fatos foram observados em testes preliminares e tornaram inviáveis a realização de testes exaustivos, igualmente aos realizados para os algoritmos genéticos seqüenciais, dentro do período de tempo desta pesquisa.

Adicionalmente, durante esta fase foi observado que o mecanismo de comunicação MPI (*messege passing interface*) apresentou limitações quanto ao tamanho das informações trocadas entre as ilhas. Neste caso, testes com tamanhos populacionais de 1000 cromossomos comprovaram a interferência na taxa de migrantes, ultrapassando as capacidades máximas admissíveis e abortando as simulações. Igualmente foi notado que o tamanho individual dos cromossomos, através do intervalo de discretização, também apresentou as mesmas limitações, pois quanto maior o seu tamanho (maior o número de bits para representar cada janela de tempo) maior era o tamanho total das informações trocadas entre as ilhas. Vale lembrar que foram consideradas as mesmas fases realizadas para os algoritmos genéticos seqüenciais, exceto as fases de pré-calibração e gerações fixas, pois decidiu iniciar-se diretamente a partir da fase de estabilidade sessão de 10. Também não foi considerada a fase de seleção global, pois foi utilizado o mesmo tamanho populacional em todas as fases. A seguir são apresentados os resultados obtidos para cada uma das fases estudadas:

6.9.1.1 Fase de Estabilidade de Sessão de 10

Em relação a esta fase foram consideradas as seguintes premissas:

- Foram adotados os melhores *sets* de cada tipo de algoritmo genético seqüencial estudado e tamanho populacional de 250 cromossomos obtidos até a Fase de Estabilidade de Sessão de 30.
- A princípio, foi assumido que os *sets* e seus respectivos parâmetros internos, obtidos como melhores para cada algoritmo genético seqüencial, permanecem válidos para os algoritmos genéticos paralelos. Foi necessária esta suposição, pois se fossem elaborados *sets* com todos os parâmetros internos possíveis, tornar-se-ia novamente inviável os estudos dos algoritmos genéticos paralelos, devido o enorme número de recursos computacionais e tempo de simulação necessários. Na etapa de calibração foram selecionados para análise os parâmetros: taxa de emigração, número e diversidade de ilhas.
- Assim, os parâmetros a serem testados em todas as ilhas relacionam-se com:
  - Taxa de migração: adotaram-se taxas de migração igual a 2%, 4% e 8%, sendo utilizada a mesma taxa para todas as ilhas em cada *set* testado. Foram adotados estes valores devido principalmente à limitação do mecanismo de comunicação MPI, observando que valores acima de 8% já apresentavam este problema de limitação computacional.
  - Diversidade: tipos diferentes de algoritmos genéticos seqüenciais utilizados em cada ilha para um mesmo algoritmo genético paralelo. Foi adotado a utilização de dois tipos de esquemas:
    - Algoritmos genéticos homogêneos: todas as ilhas do algoritmo genético paralelo apresentam o mesmo tipo de algoritmo genético seqüencial estudado, sendo os algoritmos genéticos denominados como algoritmo genético roleta, torneio e abelha rainha homogêneo.
    - Algoritmo genético heterogêneo: cada ilha do algoritmo genético paralelo apresenta um tipo diferente de algoritmo genético seqüencial estudado.
  - Número de ilhas: 3 ilhas para os algoritmos genéticos paralelos, devido este ser o menor número de ilhas que podem utilizar simultaneamente os três tipos de

algoritmos genéticos seqüenciais estudados e, portanto, apresentando o menor esforço computacional.

- Critério de parada global adotado foi de estabilidade de 10% dos melhores cromossomos da população ficarem estáveis durante 300 gerações.
- Todas as sessões dessa fase foram compostas de 10 simulações.
- No algoritmo genético heterogêneo, a ilha mestre (ilha 0) será do tipo algoritmo genético método de seleção por roleta, a ilha escrava 1 (ilha 1) será do tipo algoritmo genético método de seleção por torneio, e a ilha escrava 2 (ilha 2) será do tipo algoritmo genético evolução por abelha rainha. Esta opção foi adotada de forma arbitrária. Assim, a ilha 0 se comunica com a ilha 1, esta se comunica com a ilha 2, e finalmente a ilha 2 se comunica com a ilha 0, fechando-se assim o ciclo de comunicação.
- Realizou-se uma análise comparativa entre algoritmos genéticos seqüenciais e paralelos para a fase de estabilidade de sessão de 10.

O item G.1.1 - Fase de Estabilidade de Sessão de 10 do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Pode-se notar que taxas de migrantes maiores (igual a 8%) apresentaram melhores resultados quanto à função objetivo para os algoritmos genéticos paralelos heterogêneo e roleta homogêneo.

Verificou -se que todos os *sets* do algoritmo genético seleção por torneio homogêneo foram selecionados para a fase de sessão de 30. Este fato mostrou que o algoritmo genético seleção por torneio homogêneo pode apresentar o melhor desempenho entre os algoritmos genéticos paralelos estudados. Aparentemente, para este algoritmo genético paralelo a taxa de migrantes não apresentou influência nesta fase.

Fato interessante observado é que nenhum dos *sets* do algoritmo genético evolução por abelha rainha foram selecionados. Este fato mostra que este algoritmo genético paralelo, igualmente ao seu correspondente seqüencial, apresentou resultados inferiores em relação aos demais algoritmos genéticos estudados.

Notou-se que os tempos de processamento (evolução) do algoritmo genético evolução por abelha rainha foram sensivelmente inferiores (menor que a metade) aos demais algoritmos genéticos paralelos estudados, igualmente ao ocorrido nos algoritmos genéticos seqüenciais.

Comparação entre os algoritmos genéticos seqüenciais e paralelos

Observou-se que o número de gerações para atingir a estabilidade da evolução dos algoritmos genéticos paralelos é levemente superior, quando comparado aos algoritmos genéticos seqüenciais, para a mesma fase estabilidade de sessão de 10. Por conseqüência, o tempo de convergência (otimização) dos algoritmos genéticos paralelos foi um pouco superior quando comparado aos algoritmos genéticos seqüenciais com população de 250 cromossomos.

O tempo de convergência dos algoritmos genéticos paralelos apresentou sensível redução quando comparado aos algoritmos genéticos seqüenciais com população de 1000 cromossomos. O algoritmo genético paralelo torneio homogêneo levou em média 17:00 hs para convergir, enquanto o algoritmo genético seqüencial seleção por torneio levou até 90 hs para convergir.

Observou-se uma equivalência em relação a convergência (função objetivo) entre os melhores *sets* da fase de estabilidade de sessão de 10, do melhor algoritmo genético encontrado para os algoritmos genéticos seqüenciais (algoritmo genético seleção por torneio, população de 1000 cromossomos), em relação aos melhores *sets* encontrados na mesma fase para os algoritmos genéticos paralelos. Esta equivalência foi comprovada através dos testes de hipótese realizados.

6.9.1.2 Fase de Estabilidade Sessão de 30

Em relação a esta fase foram consideradas as mesmas premissas da fase anterior, exceto:

- Todas as sessões dessa fase foram compostas de 30 simulações.
- Foram consideradas as simulações da fase de estabilidade sessão de 10 para compor as 30 simulações por *set* para esta fase.
- Realizou-se uma análise comparativa entre os melhores resultados para os algoritmos genéticos seqüenciais e paralelos. Considerou os algoritmos genéticos seqüenciais seleção por torneio para a fase de estabilidade de 30.

O item G.1.2 - Fase de Estabilidade de Sessão de 30 do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Notou-se que o tempo de convergência do algoritmo genético heterogêneo foi um pouco inferior em comparação aos demais algoritmos genéticos paralelos analisados. Este fato pode ser justificado pelo fato do algoritmo genético heterogêneo possuir em uma de suas ilhas o algoritmo genético evolução por abelha rainha. Como observado nos algoritmos genéticos seqüenciais, este algoritmo genético paralelo apresentou tempo de convergência significativamente inferior aos demais algoritmos genéticos seqüenciais estudados. Após 30 simulações conseguiu-se diferenciar um único algoritmo genético paralelo com a melhor função objetivo, sendo este o algoritmo genético seleção por torneio homogêneo, com 4% de taxa de emigrantes.

Comparação entre algoritmos genéticos seqüenciais e paralelos

Observou-se que o melhor *set* encontrado para os algoritmos genéticos seqüenciais (*set* 06 da população de 1000 cromossomos do algoritmo genético seleção por torneio) é equivalente em termos de otimização ao melhor *set* do algoritmo genético paralelo (algoritmo genético seleção por torneio homogêneo com taxa de sobreviventes igual a 4%, população de 250 cromossomos). Este fato foi comprovado, pois a função objetivo é equivalente nos testes de hipótese realizados.

Uma possível vantagem em relação à observação anterior é que o tempo de convergência dos algoritmos genéticos paralelos são sensivelmente inferiores aos algoritmos genéticos seqüenciais. Foi observado que o tempo de convergência dos algoritmos genéticos paralelos pôde ser até 5 vezes menor em relação aos algoritmos genéticos seqüenciais. Este fato pode ser uma vantagem em situações com restrição de tempo. Uma desvantagem dos algoritmos genéticos paralelos em relação aos algoritmos genéticos seqüenciais é o maior consumo de recursos computacionais.

Outro fato importante é que, de uma forma geral, os *sets* contendo o algoritmo genético seleção por torneio homogêneo apresentaram os melhores resultados. Este fato mostra que tanto para os algoritmos genéticos seqüenciais, quanto para os algoritmos genéticos

paralelos, o algoritmo genético seleção por torneio é o que apresentou melhores resultados em termos de otimização.

6.9.1.3 Fase de Testes Adicionais

Foram realizados alguns testes adicionais para a verificação da influência de alguns parâmetros complementares na convergência dos algoritmos genéticos paralelos. Estes testes foram realizados apenas para o melhor *set* encontrado na fase de estabilidade de sessão de 30 dos algoritmos genéticos paralelos, devido às limitações de tempo, recursos computacionais e de problemas do mecanismo de comunicação MPI. Os testes adicionais avaliaram a influência dos seguintes parâmetros (micro-calibração) na convergência dos algoritmos genéticos paralelos.

a) Segundo critério de estabilidade

Observar se pela a adição de um segundo ponto de estabilidade no critério de parada obtém-se algum ganho final na otimização (função objetivo).

b) Influência do número de ilhas

Observar a influência do número de ilhas sobre a convergência dos algoritmos genéticos paralelos.

Assim, foram criados 4 *sets*, descritos a seguir:

S*et* 01: é o *set* 05 (algoritmo genético torneio homogêneo com taxa de migração igual a 4%) selecionado como melhor até a Fase de Estabilidade de Sessão de 30 dos algoritmos genéticos paralelos, utilizado como *set* de referência.

Set 02: igual ao *set* 01 anterior adicionando-se um segundo critério de parada de 10% dos melhores cromossomos da população estáveis durante 500 gerações. Entre estes critérios de parada o número de pontos de mutação simultâneos foi reduzido de 5 para 1 ponto.

S*et* 03: igual ao *set* 01 alterando-se o número de ilhas de 3 para 6 com o objetivo de verificar a influência do número de ilhas sobre a função objetivo.

- S*et* 04: igual ao *set* 03 alterou-se o número de ilhas de 6 para 9.
- Todas as sessões dessa fase foram compostas de 10 simulações.

O item G.1.3 - Fase de Testes Adicionais do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

A análise dos resultados obtidos para a fase de testes adicionais foi dividida segundo cada um dos testes realizado, conforme a seguir:

a) Segundo critério de estabilidade

Pôde ser observado que a adoção de um segundo ponto de estabilidade no critério de parada apresentou pouca melhora na convergência do algoritmo genético paralelo (melhora na função objetivo). Mesmo a melhora sendo de pequeno valor, ela foi suficiente para o *set*, que contém os dois critérios de parada, fosse considerado como o melhor pelo teste de hipótese.

Assim, pelo testes de hipótese e para manter a compatibilidade comparativa com os *sets* selecionados nos algoritmos genéticos seqüenciais, o segundo critério de parada foi adotado em fases subseqüentes da análise.

b) Influência do número de ilhas

Pôde ser observado que os algoritmos genéticos paralelos contendo 6 e 9 ilhas apresentaram melhora significativa na função objetivo, em relação ao melhor algoritmo genético paralelo contendo 3 ilhas.

Adicionalmente, notou-se que o tempo médio de processamento cresce com o aumento do número de ilhas. Vale ressaltar que a taxa de crescimento do tempo de processamento em relação ao aumento do número de ilhas é significativamente inferior, quando comparado com a taxa de crescimento do tempo de processamento em relação ao tamanho populacional nos algoritmos genéticos seqüenciais.

Este fato pode ser considerado como uma grande vantagem dos algoritmos genéticos paralelos em relação aos algoritmos genéticos seqüenciais. Por exemplo, o tempo de convergência do melhor algoritmo genético seqüencial (algoritmo genético seleção por torneio) foi acima de 70 horas. O melhor algoritmo genético paralelo encontrado na fase de Estabilidade de 30 (algoritmo genético torneio homogêneo), que apresentou função

objetivo equivalente a este melhor algoritmo genético seqüencial, apresentou tempo de convergência em torno de 18 horas.

Pode-se concluir que a adoção de dois critérios de parada e um número maior de ilhas, considerando a subpopulação de 250 cromossomos em cada ilha, traz benefícios em termos de convergência (funções objetivo) para os algoritmos genéticos paralelos. De uma forma geral, para os algoritmos genéticos paralelos pode-se afirmar que quanto maior o número de ilhas, melhor a convergência (maior a função objetivo), não sendo significativo o aumento do tempo médio de convergência dos algoritmos genéticos paralelos. Vale ressaltar que deve haver um limite para o crescimento do número de ilhas permitindo um melhor resultado da função objetivo. Este fato foi constatado se for observado que, pelo teste de hipótese, os *sets* com 6 e 9 ilhas foram considerados equivalentes.

Uma desvantagem dos algoritmos genéticos paralelos foi o crescente consumo de recursos computacionais, com o aumento do número de ilhas.

6.9.2 Etapa de Estudos Complementares

A seguir são apresentados os resultados obtidos em cada uma das fases dos estudos complementares dos algoritmos genéticos paralelos.

6.9.2.1 Fase de Reservatório dos Melhores Cromossomos

O objetivo desta fase é verificar se, partindo de uma população contendo elevado número de blocos construtivos (*building blocks*), consegue-se um ganho adicional na função objetivo em relação ao encontrado na fase de estabilidade de sessão de 30, dos algoritmos genéticos paralelos. Adicionalmente, também se deseja verificar se o tempo de convergência apresenta uma sensível redução, quando comparado a uma população inicialmente aleatória. Para tanto foram adotadas as seguintes decisões:

- Sessões de 10 simulações.
- Realizar uma análise comparativa entre algoritmos genéticos seqüenciais e paralelos para a Fase de Reservatório dos Melhores Cromossomos, bem como comparar com o melhor algoritmo genético encontrado na etapa de calibração, fase de seleção global. O objetivo desta análise é comparar os desempenhos em termos de otimização (função objetivo) entre algoritmos genéticos seqüenciais e paralelos.

- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração dos algoritmos genéticos seqüenciais, ou seja, o *set* 06 do algoritmo genético método de seleção por torneio, população de 1000 cromossomos.
- Foi utilizado, como referência também, o *set* obtido na fase de reservatório dos melhores cromossomos dos algoritmos genéticos seqüenciais, ou seja, o *set* 02.

Foram criados 3 *sets*, descritos a seguir:

Set 01: valores referenciais da melhor otimização encontrada na fase de calibração dos algoritmos genéticos seqüenciais.

Set 02: valores referenciais da fase de reservatório dos melhores cromossomos dos algoritmos genéticos seqüenciais. Deve-se observar que a fase de reservatório dos algoritmos genéticos seqüenciais apresentava uma população igual a 1000 cromossomos, e para os algoritmos genéticos paralelos cada subpopulação possui tamanho igual a 250 cromossomos. Assim, criou-se um sub-reservatório para cada ilha dos algoritmos genéticos paralelos com 250 cromossomos. O objetivo é obter uma população inicial otimizada semelhante à considerada na fase de reservatório dos melhores cromossomos dos algoritmos genéticos seqüenciais.

Set 03: valores da fase de flexibilização de reservatório dos melhores cromossomos dos algoritmos genéticos paralelos.

O item G.2.1. - Fase de Reservatório dos Melhores Cromossomos do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

Igualmente aos algoritmos genéticos seqüenciais, observou-se que foi obtido um ganho significativo em termos evolutivos (função objetivo), com a adoção de um reservatório dos melhores cromossomos, em relação ao melhor algoritmo genético e *set* obtido na etapa de calibração, fase de seleção global dos algoritmos genéticos seqüenciais.

Comparação entre os algoritmos genéticos seqüenciais e paralelos

Os algoritmos genéticos seqüenciais apresentaram melhores resultados para esta fase de reservatório dos melhores cromossomos. Este fato pode ser observado pelos testes de

hipótese realizados para a fase de reservatório dos melhores cromossomos entre algoritmos genéticos seqüenciais e paralelos. Este resultado surpreendeu, pois esperava-se pelo menos uma equivalência entre algoritmos genéticos seqüenciais e paralelos, da mesma forma ocorrida em comparações realizadas em fases anteriores. Para uma melhor comprovação desta fato sugere-se a realização de sessões maiores que 10.

6.9.2.2 Fase de Pequena Alteração da Demanda

O objetivo desta fase é verificar se para uma variação na demanda futura hipotética, mas muito próximo de uma demanda já otimizada, consegue-se reduzir de forma significativa o tempo de otimização para esta nova demanda. Para tanto, nesta fase foram adotadas as seguintes decisões:

- Foram adotadas sessões de 10 simulações.
- Realizar uma análise comparativa entre algoritmos genéticos seqüenciais e paralelos na fase de Pequena Alteração de Demanda.
- Foram utilizadas as mesmas alterações de demanda da fase de pequena alteração de demanda dos algoritmos genéticos seqüenciais.
- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração dos algoritmos genéticos paralelos, ou seja, o *set* 05 do algoritmo genético paralelo torneio homogêneo, obtido na fase de seleção de 30.

Foram adotados os seguintes *sets* nesta fase:

Set 01: valores do *set* referencial utilizando a demanda alterada.

Set 02: valores do *set* 01 alterando-se o primeiro e segundo pontos de estabilidade do critério de parada para 100 e 200 gerações respectivamente.

Set 03: valores do *set* 01 alterando-se o primeiro e segundo pontos de estabilidade do critério de parada para 50 e 100 gerações respectivamente.

Igualmente à fase de pequena alteração de demanda dos algoritmos genéticos seqüenciais foram criados dois *sets* com menor número de gerações de estabilidade para o critério de parada.

O item G.2.2. - Fase de Pequena Alteração de Demanda do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

O tempo de convergência reduziu-se praticamente pela metade, quando o número de gerações do critério de parada para o primeiro e segundo pontos de estabilidade foram reduzidos de 300 e 500 gerações para 100 e 200 respectivamente. Novamente o tempo de convergência foi reduzido pela metade, quando o número de gerações do primeiro e segundo pontos foram reduzidos para 50 e 100 gerações respectivamente. Em contrapartida, a qualidade da convergência foi reduzida em função da redução do número de gerações de estabilidade para o critério de parada. Assim, a função objetivo é tanto menor ao final da convergência, quanto maior for a redução do número de gerações de estabilidade do critério de parada. Esta conclusão pôde ser observada pois o melhor *set* selecionado nos testes de hipótese, apresentou o maior número de gerações para o primeiro e segundo pontos de estabilidade.

Comparação entre os algoritmos genéticos seqüenciais e paralelos

Comparando a fase de pequena alteração de demanda dos algoritmos genéticos seqüências e paralelos, observou-se uma ligeira melhora da função objetivo pelos testes de hipótese para os algoritmos genéticos seqüenciais. Este resultado talvez possa ser justificado pelo fato da população dos algoritmos genéticos seqüenciais apresentarem inicialmente maior diversidade genética, pois o tamanho populacional dos algoritmos genéticos seqüenciais eram de 1000 cromossomos, enquanto que cada uma das três ilhas dos algoritmos genéticos paralelos apresentavam 250 cromossomos.

6.9.2.3 Fase de Flexibilização do Intervalo de Amostragem

O objetivo desta fase é verificar a influência do intervalo de amostragem no processo de otimização (evolução). Para tanto, nesta fase foram adotadas as seguintes decisões:

- Sessões de 10 simulações.
- O intervalo de amostragem foi diminuída de 60 para 15 segundos, e com esta amostragem obteve-se maior precisão dos resultados obtidos. Verificou-se que os intervalos de amostragem menores de 15 segundos eram inviáveis para os algoritmos genéticos paralelos, devido a limitações do ambiente de simulação alcatéia.

- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração dos algoritmos genéticos paralelos, ou seja, o *set* 05 do algoritmo genético paralelo torneio homogêneo, obtido na fase de seleção de 30.
- Realizou-se uma análise comparativa entre algoritmos genéticos seqüenciais e paralelos para a Fase de Flexibilização do Intervalo de Amostragem.
- Foi utilizado, como referência, o *set* obtido na fase de flexibilização do intervalo de amostragem dos algoritmos genéticos seqüenciais.

Para esta fase foram definidos os *sets* a seguir.

Set 01: possui os valores de referência obtidos na fase de flexibilização do intervalo de amostragem para os algoritmos genéticos seqüenciais.

Set 02: possui os valores obtidos para a fase de flexibilização do intervalo de amostragem, utilizando o *set* de referência dos algoritmos genéticos paralelos.

O item G.2.3 - Fase de Flexibilização do Intervalo de Amostragem do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

Análises e comentários desta fase

As análises e comentários realizados para a fase de flexibilização do intervalo de amostragem dos algoritmos genéticos seqüenciais também são válidos para esta fase dos algoritmos genéticos paralelos.

Comparação entre os algoritmos genéticos seqüenciais e paralelos

Pôde ser observado que as otimizações obtidas para a flexibilização do intervalo de amostragem para 15 segundos foram equivalentes entre os algoritmos genéticos seqüenciais e paralelos. Esta fato pode ser verificado pelos testes de hipótese realizado.

Adicionalmente, pôde ser constado que os algoritmos genéticos paralelos apresentou uma significativa redução de tempo de otimização em torno de 4 vezes em relação aos algoritmos genéticos seqüenciais. Esta fato pode ser de grande relevância em situações em que o tempo de otimização seja um fator limitante para obtenção de resultados da otimização. Entretanto, os algoritmos genéticos paralelos apresentarem a desvantagem de consumir maior número de recursos computacionais.

6.9.2.4 Fase de Flexibilização do Intervalo de Discretização

O objetivo desta fase é verificar a influência do intervalo de discretização no processo de otimização (evolução). Para tanto, nesta fase foram tomadas as seguintes decisões:

- Sessões de 10 simulações.
- Foi utilizado, como referência, o melhor *set* obtido na etapa de calibração dos algoritmos genéticos paralelos, ou seja, o *set* 05 do algoritmo genético paralelo torneio homogêneo, obtido na fase de seleção de 30.
- Foram adotadas somente taxas de discretização igual a 8 bits, devido às limitações em função do tamanho das informações trocadas entre as ilhas (cromossomos emigrantes) no mecanismo de comunicação MPI (*messege passing interface*).
- Realizar uma análise comparativa entre algoritmos genéticos seqüenciais e paralelos na fase de flexibilização do intervalo de discretização.
- Foi utilizado, como referência, o *set* obtido na fase de flexibilização do intervalo de discretização dos algoritmos genéticos seqüenciais.

Foram definidos os *sets* a seguir para esta fase:

Set 01: possui os valores de referência obtidos na fase de flexibilização do intervalo de amostragem para os algoritmos genéticos seqüenciais.

Set 02: possui os valores obtidos para a fase de flexibilização do intervalo de discretização de 8 bits, utilizando o *set* de referência dos algoritmos genéticos paralelos.

O item G.2.4 - Fase de Flexibilização do Intervalo de Discretização do Apêndice G – Testes de Hipótese para os Algoritmos Genéticos Paralelos, apresenta os resultados dos testes de hipótese desta fase.

<u>Análises e comentários desta fase</u>

As análises e comentários realizados para a fase de flexibilização do intervalo de discretização dos algoritmos genéticos seqüenciais também são válidos para esta fase dos algoritmos genéticos paralelos.

<u>Comparação entre os algoritmos genéticos seqüenciais e paralelos</u>

Pôde ser observado que as otimizações obtidas para a flexibilização do intervalo de discretização de 8 bits foram equivalentes entre os algoritmos genéticos seqüenciais e

paralelos. Este fato pôde ser verificado pelos testes de hipótese realizado.

Adicionalmente, pôde ser constado que os algoritmos genéticos paralelos apresentaram um tempo de otimização superior aos algoritmos genéticos seqüenciais. Este fato pode ser uma desvantagem adicional, além de consumir um maior número de recursos computacionais, dado que os resultados de otimização foram equivalentes ao final do processo de otimização.

No capítulo 7 é apresentada uma compilação dos resultados deste trabalho de pesquisa, bem como as contribuições e futuras linhas de pesquisas que podem ser desenvolvidas.

Neste capítulo é apresentada a compilação dos resultados obtidos neste trabalho de pesquisa, bem como as contribuições e futuras linhas de pesquisa.

7 COMPILAÇÃO DOS RESULTADOS

"Conhecimento científico é o que é produzido pela investigação científica, através de seus métodos. Surge não apenas da necessidade de encontrar soluções para problemas de ordem prática da vida diária, mas do desejo de fornecer explicações sistemáticas que possam ser testadas e criticadas através de provas empíricas."

Espírito Científico
Francisco Saiz, Sociedada dos Cientistas Mortos, 2000

A seguir são apresentadas as principais conclusões e contribuições obtidas ao final deste trabalho de pesquisa. Adicionalmente, são apresentadas algumas linhas de pesquisas que podem trazer avanços adicionais ao trabalho realizado, bem como alguns aspectos que não puderam ser abordados e que merecem ser melhor explorados através de pesquisas futuras.

7.1 Conclusões e Comentários Gerais da Pesquisa

A partir do trabalho de pesquisa realizado chegou-se aos seguintes comentários e conclusões gerais, em duas áreas específicas: Sistemas Aeronáuticos e Inteligência Artificial.

7.1.1 Área de Sistemas Aeronáuticos

O modelo de otimização de demanda proposto mostrou-se efetivo na otimização de uma demanda de tráfego aéreo em uma infra-estrutura aeronáutica previamente conhecidas, com diversos períodos de supersaturação (acima de 120% da capacidade nominal declarada dos setores), que caracteriza o problema de desbalanceamento entre demanda e capacidade em infra-estrutura aeronáutica. O objetivo final de reduzir a carga de trabalho de gerenciamento a patamares considerados como suportáveis (abaixo de 120%

da capacidade nominal declarada) em todos os setores da infra-estrutura aeronáutica estudada foi alcançado. Desta forma, os Controladores de Tráfego Aéreo são submetidos a uma menor carga de trabalho de gerenciamento, permitindo-se assim garantir a segurança (*safety*) em níveis aceitáveis.

A comprovação deste fato foi obtida através de um estudo de caso real, englobando um cenário aeronáutico brasileiro de elevada demanda de tráfego aéreo, englobando as cidades de Belo Horizonte, Brasília, Rio de Janeiro e São Paulo. Através deste estudo de caso conseguiu-se obter a otimização da demanda abaixo de um patamar crítico, definido como de saturação aceitável em todos os setores deste cenário aeronáutico, para a melhor otimização obtida na pesquisa.

Na verdade, após a melhor otimização, muitos dos setores que apresentavam demanda sem otimização em supersaturação, tiveram suas demandas reduzidas abaixo da capacidade nominal declarada.

Adicionalmente, observou-se que, em outras otimizações, também conseguiu-se obter a demanda otimizada em todos setores abaixo do patamar de saturação aceitável.

Apesar da rigidez imposta pelos limites da janela de tempo, de forma a produzir a menor interferência no fluxo e serviços de tráfego aéreo, observou-se que o processo de otimização trouxe sensível redução da carga de trabalho global de gerenciamento. Este fato demonstra a eficiência do modelo de otimização de demanda em infra-estrutura aeronáutica através de algoritmos genéticos.

Um fato importante a ser comentado é que o poder de otimização apresenta-se efetivo até um certo patamar de crescimento de demanda. Esta limitação de otimização ocorre tanto em função dos limites impostos para cada parâmetro interno ao modelo de otimização de demanda, quanto pela capacidade da infra-estrutura aeronáutica estudada em suportar aumentos adicionais de demanda. Caso a flexibilização das janelas de tempo seja inviável, devido ao elevado número de atrasos gerados nos vôos, a alternativa mais viável, neste caso, seja a ampliação da infra-estrutura aeronáutica existente.

Para poder usufruir os benefícios proporcionados pela otimização de demanda, os tempos por ela determinados (decolagem nos aeroportos, permanência em cada setor, entrada de vôos externos na infra-estrutura aeronáutica analisada) devem ser cumpridos

rigorosamente. Quanto mais rigor ocorrer no cumprimento destes tempos estabelecidos, maiores serão os benefícios conseguidos através da otimização. Partindo-se deste pressuposto, pode-se observar que o modelo de otimização de demanda apresenta grande rigidez em termos de cumprimento dos tempos por ele estabelecido. Para a sua aplicação em um caso prático, é adequado um novo planejamento de todo o plano de vôo existente. Além disso, toda vez que a demanda alterar significativamente poderá necessitar um replanejamento de vôos.

No estudo de caso estudado foi verificado que uma alteração sugerida de 2% na demanda original pode ser considerada elevada, mesmo utilizando uma população inicial não aleatória. Verificou-se que o tempo de otimização para uma nova demanda, com uma população inicial não aleatória, foi praticamente igual à metade do tempo de otimização a partir de uma população totalmente aleatória. Deve-se lembrar que o tempo médio de otimização da demanda inicial, não otimizada e com população aleatória, foi em torno de 72 hs, para o algoritmo genético seleção por torneio, população de 1000 cromossomos, dois pontos de estabilidade para o critério de parada e intervalo de amostragem de 60 s. Provavelmente alterações de demanda inferiores a 2% possam apresentar tempos de otimização sensivelmente inferiores.

O modelo de otimização proposto deve ser visto como uma ferramenta de auxílio, que pode ajudar na utilização mais racional da infra-estrutura aeronáutica existente.

Observou-se, pelo estudo de caso realizado, que a seleção dos melhores cenários aeronáuticos (cromossomos) otimizados, baseado nos valores da função objetivo, pode ser considerado como uma primeira etapa de seleção. A seleção e análise de cenários baseado na função objetivo pode não garantir, em todos os setores da infra-estrutura aeronáutica analisada, a obtenção de demanda sempre inferior ao patamar de saturação aceitável.

Observou-se que os cenários aeronáuticos obtidos com valores de função objetivo elevados e próximos, não apresentaram diferenças significativas em seus diagramas de análise de situação, bem como, nos custos hipotéticos e atrasos globais gerados. Este fato sugere que, para o problema de otimização de demanda em infra-estrutura aeronáutica, possa haver mais de uma solução a ser adotada em um caso real.

O conhecimento especialista da área e do problema em análise, bem como a experiência adquirida pela observação e análise de otimizações obtidas anteriormente, tornam-se fundamentais em um análise criteriosa para a seleção de cenários otimizados, viáveis de serem implantados em um caso real. Igualmente, esta experiência pode tornar-se valiosa em futuras novas demandas.

A utilização de diagramas de análise de situação para a diferenciação entre diferentes cenários otimizados é fundamental, pois ele acaba sendo a única forma de se ter uma visão geral e ao mesmo tempo detalhada da demanda em todos os setores da infra-estrutura aeronáutica.

Para uma dada infra-estrutura aeronáutica, demanda a ser otimizada e parâmetros internos ao modelo de otimização (janelas de tempo), pode ocorrer que os resultados de otimização (cenários aeronáuticos otimizados) em certos estágios de evolução (valores da função objetivo) já possam ser suficientes para a sua aplicação em um caso real. Desta forma, nem sempre há a necessidade de se obter o melhor cenário aeronáutico otimizado, podendo-se encontrar e aplicar cenários aeronáuticos intermediários.

Observou-se, pelo estudo de caso realizado, que certos parâmetros do modelo de otimização proposto apresentam maior influência na carga de trabalho de gerenciamento. Estes parâmetros são: atrasos nos demais aeroportos (Belo Horizonte e Brasília) e atrasos e adiantamentos de entrada dos vôos externos no cenário aeronáutico. Aspecto importante a ser comentado e, que influência o resultado obtido, é que as janelas de tempo associadas a estes dois parâmetros apresentam os maiores valores entre todas as janelas de tempo adotadas. Caso todas as janelas possuíssem o mesmo tamanho, resultados diferentes poderiam ser observados. A obtenção destes resultados é importante, pois em situações de maior demanda em relação à estudada, a identificação destes parâmetros de maior influência são fundamentais no momento de flexibilização dos parâmetros do modelo. Estes parâmetros provocam maior redução na carga de trabalho global de gerenciamento, bem como, menor interferência nos serviços de transporte aéreo prestados, pois não geram atrasos adicionais em áreas críticas (de alta demanda de tráfego aéreo), como aeroportos e áreas de controle terminais de São Paulo e Rio de Janeiro.

Um fato interessante a ser observado é que, quanto maior for a janela de tempo de um parâmetro do modelo de otimização de demanda em infra-estrutura aeronáutica, maior poderá ser a sua influência sobre a carga de trabalho de gerenciamento global do cenário.

Outra alternativa interessante é a aplicação de pequenas flexibilizações simultâneas em diferentes janelas de tempo. Estas podem apresentar melhores resultados, em termos de redução de carga de trabalho global, quando comparada a flexibilizações maiores em único tipo de janela de tempo. Este fato é relevante, pois em muitos casos, flexibilizar demasiadamente um único tipo de janela de tempo pode significar penalizar, em muito, os serviços de transporte aéreo realizados. Em algumas circunstâncias, diversas pequenas flexibilizações podem trazer menos penalidades nos serviços de transporte aéreo prestados.

Outro fato importante, observado pelo estudo de caso, é que o intervalo de amostragem apresenta interferência no tempo de otimização, bem como na qualidade dos resultados obtidos. Este parâmetro introduz um erro, em certas condições, na demanda contabilizada para um dado setor. Este erro, apesar de interferir nas respostas obtidas, aumenta o nível de segurança (*safety*) considerado, pois a demanda real será inferior a demanda otimizada. O efeito deste erro é reduzido com a redução do tamanho da amostragem. No caso ideal, intervalos de amostragem igual a 1 segundo eliminam este erro.

7.1.2 Área de Inteligência Artificial

Pelo processo de calibração dos algoritmos genéticos observou-se que eles consomem grande quantidade de recursos computacionais e tempo de simulação. Mesmo os parâmetros estudados não puderam ser analisados de forma minuciosa, devido ao elevado esforço computacional necessário. Assim, a opção escolhida foi aumentar a diversidade de *sets* e algoritmos genéticos a serem testados, em detrimento de uma maior precisão obtida para os resultados. Em função dos resultados obtidos para o estudo de caso, tal adoção, a princípio, foi a melhor opção. Outro aspecto que justifica tal decisão é que não necessariamente deseja-se encontrar a melhor otimização (que produz a menor redução de carga de trabalho de gerenciamento global). O que se deseja

é a obtenção de cenários aeronáuticos com demanda abaixo do patamar de saturação aceitável, em todos os setores da infra-estrutura aeronáutica, e no menor tempo de otimização.

Pôde ser observado, pelo processo de calibração, que tanto a qualidade dos resultados da otimização (valores da função objetivo) quanto o tempo de otimização são os parâmetros que variam entre os diferentes *sets* testados.

O processo de calibração dos algoritmos genéticos mostrou-se extremamente exaustivo, devido aos seguintes fatores:

- Elevado número de parâmetros de controle dos algoritmos genéticos a serem testados.
- A inter-relação ou dependência entre os diversos parâmetros internos (micro-calibração), e os diferentes mecanismos que podem ser aplicados em cada operador genético (macro-calibração) dos algoritmos genéticos.
- Os parâmetros da micro e macro calibração também apresentam inter-relação com os parâmetros do modelo de otimização, que estão associados à infra-estrutura aeronáutica. Assim, em um caso ideal, para a seleção do melhor conjunto de parâmetros, associados aos algoritmos genéticos e modelo de otimização, seria necessário a criação de *sets* na forma combinatória entre todos estes parâmetros apresentados. Tal volume de testes acaba se tornando totalmente inviável. Além disto, deve-se questionar se o esforço computacional e o tempo de simulação justificariam os resultados obtidos, pois pode haver um patamar de resposta (otimização) que já seja aceitável para o problema estudado.
- Elevado tempo de processamento necessário em cada otimização. Por exemplo, o tempo médio de otimização para o algoritmo genético seleção por torneio, população de 1000 cromossomos, dois pontos de estabilidade para o critério de parada e intervalo de amostragem de 15s, foi em torno de 231hs.
- Necessidade de elevado número de simulações dentro de cada *set*, de forma a permitir uma melhor aferição estatística, para comparar e determinar os melhores *sets*.

O algoritmo genético método de seleção por torneio apresentou os melhores resultados (maiores valores para a função objetivo) em todos os estudos realizados, tanto para os algoritmos genéticos seqüenciais quanto para os algoritmos genéticos paralelos.

Portanto, o algoritmo genético seleção por torneio pode ser considerado o mais apto a ser utilizado no problema de otimização estudado.

Observou-se que, de uma forma geral, tamanhos populacionais maiores apresentaram melhores otimizações. O inconveniente é que o tempo de otimização aumenta de forma significativa com o crescimento populacional. Para o algoritmo genético evolução por abelha rainha este crescimento do tempo de otimização foi o menor entre todos os algoritmos genéticos estudados.

O operador mutação mostrou-se como o principal operador genético, ou seja, apresentou a maior influência no modelo de otimização de demanda proposto. Este fato é justificado principalmente na adoção de mais de um ponto de mutação simultâneos, bem como na utilização de taxas elevadas de mutação nos melhores *sets* dos algoritmos genéticos estudados.

A adoção de mais de um ponto de mutação simultâneos (adotado 5 pontos de mutação simultâneo na maioria dos casos) desde o início do processo de otimização trouxe melhores resultados quando comparado com apenas 1 (um) ponto de mutação, desde o início da otimização. Isto pode ser justificado pelo fato do cromossomo adotado ser extremamente longo, apresentando tamanho de 35.085 bits, para o intervalo de discretização igual a 5 bits. Observou-se que a alteração em apenas um bit provoca pouco ganho na função objetivo, durante o processo evolutivo de geração à geração. A adoção de vários bits de mutação simultâneos e com elevada probabilidade (elevada taxa de mutação), apresentou melhores resultados ao final do processo de otimização.

Igualmente, a adoção de dois pontos de estabilidade para o critério de parada, sendo o primeiro com mais de um ponto de mutação simultâneos, e o segundo com apenas 1 (um) ponto de mutação, resultou num ganho quanto à qualidade dos resultados da otimização. Esta comparação é realizada com a adoção de apenas um ponto de estabilidade para o critério de parada, seja este com um ou mais pontos de mutação simultâneos. Deve ser observado que, no segundo ponto de estabilidade do critério de parada, mantém-se a taxa de mutação elevada. A adoção de dois pontos de estabilidade, para o critério de parada, pode ser justificada pelo fato que, em estágios mais elevados de otimização, grandes alterações nos genes de um cromossomo, provocados pelo

elevado número de pontos de mutação simultâneos, acabam provavelmente se tornando mais destrutivas que construtivas para o processo de otimização. Normalmente, em estágios mais avançados do processo de otimização, pequenas alterações nos genes do cromossomo tornam-se mais benéficas.

O algoritmo genético evolução por abelha rainha apresentou resultados inferiores quanto à qualidade dos resultados da otimização, quando comparado aos algoritmos genéticos método de seleção por roleta e torneio. Entretanto, ele apresenta, como característica interessante, um tempo de otimização (convergência) significativamente inferior aos demais algoritmos genéticos. Esta característica pode ser relevante em situações que haja restrição no tempo de otimização.

Observou-se uma certa equivalência em termos de qualidade dos resultados da otimização entre algoritmos genéticos seqüenciais e paralelos. Desta forma, para uma dada população de um algoritmo genético seqüencial, existe um número de ilhas dos algoritmos genéticos paralelos que podem apresentar otimizações equivalentes (quanto ao valor da função objetivo). A vantagem dos algoritmos genéticos paralelos é a sensível redução no tempo de otimização. Esta redução de tempo é ainda mais acentuada quando é utilizado o algoritmo genético evolução por abelha rainha em cada uma das ilhas dos algoritmos genéticos paralelos.

Observou-se também que a adoção da técnica de utilizar um reservatório dos melhores cromossomos obtidos em otimizações anteriores, provocou um ganho significativo na qualidade dos resultados da otimização. Apesar de nesta técnica a diversidade genética reduzir sensivelmente, ou seja, a pressão seletiva tornar-se elevada, mesmo assim obteve-se ganhos significativos quanto aos resultados da otimização. Uma possível justificativa é que construindo-se reservatórios dos melhores cromossomos, obtém-se populações com grande número de blocos construtivos (*buildng blocks*), que quando combinados podem favorecer ganhos adicionais em termos de resultados ao final da convergência. Adicionalmente, neste caso, notou-se uma significativa redução no tempo de otimização, quando comparado às otimizações com populações iniciais aleatórias.

Outro fato importante observado é que o intervalo de discretização apresenta interferência no processo de otimização. Quanto menor for este intervalo, maior a

interferência. Este efeito ocorre, pois a função objetivo a ser otimizada pode apresentar diversos máximos locais, e a redução do tamanho deste intervalo permite que a função fique mais facilmente presa nestes máximos locais. Uma alternativa para a solução deste problema é a elevação do número de pontos de mutação simultâneos, aumentando-se a probabilidade de se sair destes máximos locais.

7.2 Contribuições

As principais contribuições deste trabalho de pesquisa podem ser divididas em três segmentos: aeronáutico, inteligência artificial e computação paralela.

7.2.1 Área de Sistemas Aeronáuticos

As contribuições desse trabalho de pesquisa em sistemas aeronáuticos são:

- A criação de um modelo de otimização global para o problema de desbalanceamento entre capacidade e demanda em infra-estrutura aeronáutica.
- A proposição de uma estimativa de cálculo de carga de trabalho global de gerenciamento, baseada em curvas de carga de trabalho de setores, na capacidade nominal declarada dos setores, excesso de demanda e no tempo de duração destes excessos a partir do patamar de congestionamento (80% da capacidade nominal declarada).
- A análise e proposta de uma solução para um cenário aeronáutico real e crítico, quanto ao problema de desbalanceamento entre capacidade e demanda dentro do contexto brasileiro. Para esse cenário foram realizadas análises com o objetivo de verificar a influência de cada janela de tempo, do modelo de otimização, sobre a carga de trabalho de gerenciamento global. Finalmente, verificou-se quais janelas de tempo e em que condições apresentavam maior interferência na carga de trabalho global de gerenciamento.
- A obtenção de diagramas de análise de situação (perfis de demanda) que possam ser aplicados em um contexto real para um cenário aeronáutico brasileiro crítico.
- A adoção de parâmetros auxiliares, tais como, custo hipotético, atrasos em aeroportos e setores do espaço aéreo, que contribuem na seleção do cenário mais adequado entre dois ou mais cenários aeronáuticos otimizados.

- O modelo de otimização de demanda (MOD) em infra-estrutura aeronáutica mostrou-se com grande potencial a ser aplicado dentro do planejamento do fluxo do tráfego aéreo (ATFM - *Air Traffic Flow Management*), mais especificamente na fase de planejamento estratégico, dado o elevado tempo de otimização necessário para o obtenção dos cenários otimizados.

7.2.2 Área de Inteligência Artificial

As contribuições desse trabalho de pesquisa em inteligência artificial são:

- A utilização de algoritmos genéticos seqüenciais e paralelos como técnica de otimização em um problema de otimização de alta complexidade ligada a área aeronáutica. Especificamente a adoção dos seguintes tipos de algoritmos genéticos seqüenciais: seleção roleta e torneio, e evolução por abelha rainha. Para o algoritmo genético paralelo em ponte em duas modalidades: homogêneos (todas as ilhas com o mesmo tipo de algoritmo genético) e heterogêneo (ilhas com tipos diferentes de algoritmos genéticos).
- A utilização de dois pontos de estabilidade para o critério de parada, no qual ocorre a redução do número de pontos de mutação simultâneos do primeiro para o segundo ponto de estabilidade, com o objetivo de evitar o efeito de excesso de mutação em estágios mais avançados de evolução dos algoritmos genéticos.
- A adoção dos algoritmos genéticos paralelos através de topologia em ponte com passagem de bastão entre ilhas.
- No algoritmo genético evolução por abelha rainha a utilização de mutação multiponto para os operadores mutação normal e supermutação.
- A utilização de reservatório de cromossomos como um processo de otimização adicional, composto pelos melhores cromossomos de otimizações anteriores.

7.2.3 Área de Computação Paralela

A contribuição nessa área refere-se à adoção dos algoritmos genéticos paralelos em uma topologia em ponte com controle de parada global através de bastão (*token*), utilizando o ambiente de comunicação MPI (*Messenge Passing Interfase*).

7.3 Dificuldades Encontradas

As dificuldades encontradas nesse trabalho de pesquisa foram:

- Durante a realização do estudo de caso observaram-se problemas de convergência prematura, principalmente para o algoritmo genético evolução por abelha rainha, bem como na fase de reservatório dos melhores cromossomos. Este fato pode ter sido ocasionado devido à função objetivo apresentar vários pontos de máximos locais.
- Influência do intervalo de amostragem sobre a função objetivo. Este fato fez com que fossem utilizados intervalos de amostragem maiores (60 segundos) do que o ideal (1 segundo) a ser utilizado.
- Influência da diminuição do intervalo de discretização sobre a função objetivo, acentuando o problema de convergências prematuras. Foi observado que aumentando ainda mais do número de pontos de mutação simultâneos (superior a 5 pontos), diminuía a probabilidade da função objetivo ficar "presa" em máximos locais.
- Dificuldade de analisar, de forma mais precisa, os *sets* gerados, em função do elevado tempo de simulação necessário para a calibração de cada algoritmo genético, e do elevado número de *sets* a serem testados.
- Igualmente, dado o elevado tempo de simulações e interdependência entre os parâmetros de micro-calibração, macro-calibração e do modelo de otimização, foi necessária a criação de *sets* de forma combinatória entre todos estes parâmetros. Esta fato reduziu a possibilidade de se analisar de forma mais precisa (menor intervalo de valores testados) cada um dos parâmetros estudados.

7.4 Sugestões de Linhas de Pesquisa

Foram identificadas diversas linhas de pesquisas que podem ser estudadas no sentido de melhorar o desempenho do modelo de otimização de demanda proposto, bem como de analisar diversos aspectos não cobertos por este trabalho de pesquisa. A seguir são apresentadas algumas dessas linhas de pesquisa que merecem ser abordadas futuramente.

7.4.1 Área de Sistemas Aeronáuticos

Dentro da perspectiva da área de sistemas aeronáuticos, mais precisamente, gerenciamento de tráfego aéreo (ATM – *Air Traffic Management*), existem diversas possibilidades que podem ser pesquisadas com o objetivo de aperfeiçoar o modelo de otimização de demanda em infra-estrutura aeronáutica.

7.4.1.1 Inclusão de Vôos com Escala e com Pólos Concentradores de Tráfego

As rotas dos vôos, dentro deste trabalho de pesquisa, foram consideradas somente como diretas, ou seja, sem considerar aeroportos intermediários entre o aeroporto origem e destino em cada rota. Em um cenário aeronáutico poderão ser considerados vôos com escala e com pólos concentradores de tráfego (*hub and spoke)* (SILVEIRA, 2003).

Estes vôos poderão ser incorporados no modelo de otimização de demanda atual, através da criação de rotas e janelas de tempo de aeronaves associados a estes aeroportos intermediários.

7.4.1.2 Inclusão de Vôos não RPL

No cenário aeronáutico analisado foram considerados apenas vôos dentro da classe denominada de Planos de Vôo Repetitivos (RPL - *Repetitive flight plans*), vôos regulares que apresentam sempre as mesmas características e horários de realização. Os RPLs são vôos regulares que se realizam pelo menos uma vez por semana, com um total de no mínimo 10 vôos, e previsão de utilização mínima de 2 meses.

Os vôos não repetitivos podem ser: vôos alternativos e autônomos. Estes vem se tornando cada vez mais comuns, podendo, em um futuro próximo, produzirem grande impacto na demanda da infra-estrutura aeronáutica nacional (SIEWERDT, 2002). Assim, futuras pesquisas utilizando o modelo de otimização de demanda poderão levar em consideração as estimativas de ocorrência de tais vôos na infra-estrutura aeronáutica. Adicionalmente, deverá ser analisado a influência destes vôos sobre a carga de trabalho de gerenciamento global, bem como em cada setor da infra-estrutura aeronáutica analisada. Também poderá ser realizado um estudo sobre o impacto destes vôos não repetitivos no tempo de otimização dos algoritmos genéticos.

7.4.1.3 Incorporação de Novos Cenários Aeronáuticos

O modelo de otimização de demanda é flexível, podendo acomodar novas infra-estruturas (cenários aeronáuticos) de menores ou maiores dimensões ao analisado no estudo de caso. Estes novos cenários aeronáuticos poderão até considerar um ou mais territórios nacionais, áreas ocêanicas, um pais ou continente. Para tanto, deverão ser obtidas as informações de entrada do modelo de otimização de damanda, referente a estes novos cenários aeronáuticos.

Adicionalmente, poderá ser avaliado o tempo de otimização em função do aumento do tamanho do cenário aeronáutico, comparando ao cenário aeronáutico estudado neste trabalho de pesquisa.

7.4.1.4 Incorporação de Outros Fatores na Otimização

O parâmetro de otimização considerado no modelo de otimização de demanda está relacionado exclusivamente ao excesso de demanda em cada setor de um cenário aeronáutico. Outros parâmetros, tais como, os atrasos em aeroportos e setores do espaço aéreo, bem como custos hipotéticos, foram considerados apenas como fatores adicionais ou auxiliares, estimados somente ao final do processo de otimização. Neste caso, um ou mais parâmetros poderão ser considerados como relevantes no processo de otimização necessitando, portanto, que sejam incorporados na função objetivo de forma parametrizada.

7.4.1.5 Adoção de Carga de Trabalho de Gerenciamento mais Realística

A carga de trabalho de gerenciamento global é o núcleo da função objetivo dos algoritmos genéticos, direcionador do processo de evolução. Neste trabalho de pesquisa ela foi considerada como um bom estimador para o problema em análise. Esta estimativa foi adotada na pesquisa, dada à complexidade e dificuldade de definição mais precisa da carga de trabalho de gerenciamento no controle de tráfego aéreo.

Futuros trabalhos de pesquisa poderão realizar uma análise mais precisa e criteriosa da carga de trabalho de gerenciamento, principalmente relacionando-a com a carga de trabalho mental dos Controladores de Tráfego Aéreo. A carga mental destes profissionais é extremamente elevada e envolve diversas áreas do conhecimento

humano, necessitando de pesquisas e trabalhos específicos somente para o seu tratamento.

Estas pesquisas e trabalhos poderão ser incorporados no modelo de otimização de demanda proposto, tornando-o ainda mais preciso e realístico quanto ao processo de otimização de demanda.

7.4.1.6 Incoporação de otimizaçõeos em aeroportos

Conforme apresentado no capítulo 5 a proposta do modelo de otimização de demanda em infra-estrutura aeronáutica pode incorporar otimizações internas aos aeroportos, podendo estas até serem incorporadas na função objetivo. Para tanto, deverá ser estudado as circunstâncias que ocorrem superlotação e a logística de gerenciamento das aeronaves dentro dos aeroportos, pistas, taxiamento, garagem etc.

7.4.1.7 Integração com Outros Sistemas Aeronáuticos

A proposta do modelo de otimização de demanda em infra-estrutura aeronáutica não pode ser vista como uma futura ferramenta isolada de gerenciamento de tráfego aéreo. Este modelo deve estar acoplado a outras aplicações que apresentam o objetivo de auxiliar na obtenção de um melhor balanceamento entre a capacidade e demanda em uma infra-estrutura existente. Assim, o modelo de otimização de demanda dentro do contexto de Gerenciamento de Fluxo de Tráfego Aéreo (ATFM - *Air traffic flow management*), pode interagir com diversas outras ferramentas.

Por exemplo, em (DALAHAYE, 1995) é proposto um modelo de otimização de setores do espaço aéreo, também baseado em algoritmos genéticos. Este trabalho propõem a resetorização do espaço aéreo em função do volume de tráfego aéreo. Desta forma, quando uma infra-estrutura apresenta-se com setores saturados, os espaços aéreos são divididos. O objetivo desta divisão é fornecer setores balanceados em termos de tráfego e, portanto, de carga de trabalho de gerenciamento para os controladores de tráfego Aéreo. Desta forma, os modelos de otimização de demanda e resetorização poderão trabalhar de forma complementar e cooperativa.

Outro exemplo, seria a utilização do MOD como um elemento ou agente dentro do contexto de gerenciamento de decisões (CDM - *Colaborative Decision Making*). O CDM tem por objetivo assegurar as operações para todas as fases de vôo, através do

balanceamento e consolidação das decisões tomadas a partir dos diversos serviços de transporte aéreo. Dentro deste contexto, o MOD seria um elemento de decisão bem como de fornecimento de informações a diversas outras áreas dentro do CDM.

7.4.1.8 Integração dentro do Contexto CNS/ATM

A concepção do sistema CNS/ATM (*Communications, Navigation and Surveillance Systems / Air Traffic Management*) envolve a integração e a convivência de diversos sistemas e tecnologias, bem como o desenvolvimento de diversas pesquisas, inclusive no campo das ciências computacionais.

Dentro deste contexto, o modelo de otimização de demanda deve ser pesquisado e integrado dentro do campo de Gerenciamento de Tráfego Aéreo (ATM - *Air Traffic Management*), mais precisamente, no balanceamento entre capacidade e demanda no ambiente CNS/ATM.

Assim, o modelo de otimização de demanda poderá ser traduzido como uma ferramenta computacional que tem por objetivo auxiliar na organização e no gerenciamento do espaço aéreo, podendo ser aplicado, à princípio, a nível estratégico, e quando possível a nível pré-tático, devido estarem associado a atividades de mais curto prazo.

De forma complementar, com o objetivo de tornar o fluxo de informações mais eficiente e rápido, podem ser investigadas formas automatizadas de coletar (entrada) e distribuir (saída) as informações do modelo de otimização de demanda. Este fluxo de informações pode ser distribuído entre aeronaves em vôo, aeroportos, APPs (*Approach control*), ACCs (*Area Control Center)*, ATC (*Air Traffic Control*), ATMF (*Air Traffic Flow Management*) entre outros através de comunicação via enlace (*datalink*) de dados digitais.

7.4.2 Área de Inteligência Artificial

Dentro da perspectiva de inteligência artificial, mais especificamente algoritmos genéticos, existem diversas possibilidades de pesquisa com o objetivo de aperfeiçoar o modelo de otimização de demanda em infra-estrutura aeronáutica. A seguir são apresentadas algumas destas linhas de pesquisa.

7.4.2.1 Utilização de Meta Algoritmos Genéticos

Como observado durante o estudo de caso, existe um enorme esforço para a realização do processo de calibração dos algoritmos genéticos. O objetivo é encontrar o conjunto de parâmetros internos (micro-calibração) e mecanismos em cada operador genético (macro-calibração), que permitam a melhor qualidade de convergência (função objetivo) dos algoritmos genéticos, no menor tempo possível. Este enorme esforço é gasto devido ao fato que a micro e macro-calibração são dependentes entre si, podendo também ser dependentes dos parâmetros internos do problema em análise.

Uma alternativa a ser investigada procurando evitar este excessivo esforço de calibração é através da utilização de uma classe de algoritmos genéticos denominada de meta-algoritmos genéticos. Neste caso, um meta-algoritmo genético é acoplado ao algoritmo genético principal, com o objetivo de encontrar o conjunto de parâmetros internos que sejam mais adequados a este algoritmo genético principal.

O meta-algoritmo genético fornece os valores dos parâmetros internos do algoritmo genético principal, tais como, taxa de mutação e reprodução em tempo de execução do algoritmo genético principal, através de um mecanismo de retroalimentação (*feedback*), a partir do valor médio da aptidão populacional. A figura 7.1 apresenta, de forma esquemática, o acoplamento entre o meta-algoritmo genético e o algoritmo genético principal (HOLLAND, 2000).

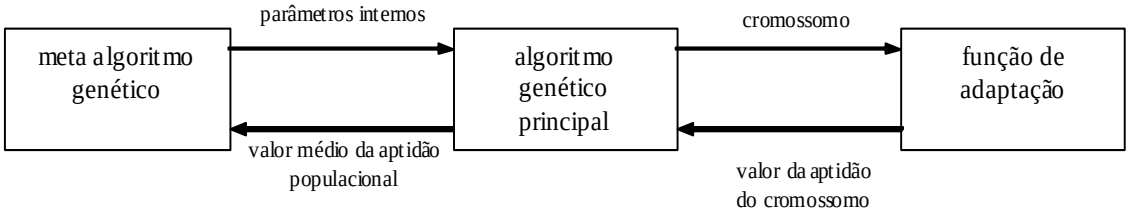

Figura 7.1: Acoplamento entre meta-algoritmo genético e algoritmo genético principal

7.4.2.2 Refinamento dos Algoritmos Genéticos Estudados

Adotou-se, devido ao grande esforço computacional exigido, que a pesquisa privilegiaria a diversidade de possibilidades de testes e algoritmos genéticos a serem estudados, em detrimento de uma maior precisão na busca dos valores dos parâmetros dos algoritmos genéticos. Assim, de forma complementar e objetivando fornecer maior comprovação dos resultados obtidos pelo estudo de caso, seria interessante realizar pesquisas que

permitissem uma análise mais aprofundada e detalha de alguns aspectos não cobertos por este trabalho de pesquisa. Entre estes aspectos podem ser citados:

- Para os algoritmos genéticos, poderiam ser realizados estudos com sessões maiores, de 50 ou mais simulações, com o objetivo de verificar se os *sets* selecionados para cada algoritmo genético estudado são comprovadamente os de melhor convergência para o modelo de otimização de demanda em infra-estrutura aeronáutica.
- Utilizar e analisar variações de intervalos, entre os *sets* estudados, com menor granularidade, de forma a refinar os melhores valores dos parâmetros internos dos algoritmos genéticos estudados.
- Analisar, de forma mais detalhada, a influência do tamanho da população, pontos de mutação simultâneos e penalidades sobre a qualidade da convergência (função objetivo), através de um maior intervalo de valores e testes a serem executados.
- Realizar, desde o início do processo de calibração, simulações com intervalos de amostragem igual a 1 segundo, suposto o melhor intervalo para o problema abordado, e comparar os resultados obtidos, com os resultados encontrados no estudo de caso realizado nesta trabalho de pesquisa.
- Considerar diferentes intervalos de discretização e verificar, com maior precisão, a sua influência sobre o tempo de convergência, bem como na qualidade da solução encontrada para o problema de otimização de demanda em infra-estrutura aeronáutica.

7.4.2.3 Aperfeiçoamento dos Métodos de Otimização

Um dos principais problemas encontrados durante a pesquisa foi o elevado tempo de otimização. Uma forma de procurar reduzi-lo é através de estudos relacionados a pressão seletiva dos algoritmos genéticos. Uma forma de estudar o comportamento do problema de otimização de demanda em função da pressão seletiva é através de análises do comportamento de outros métodos de seleção (por exemplo: truncagem, hierárquico, estocástico, etc), diferentes dos estudados. Estes métodos poderão ser aplicados tanto nos algoritmos genéticos seqüenciais quanto nos paralelos.

Outra forma de alterar a pressão seletiva é através do escalonamento da função objetivo, podendo manter-se os métodos de seleção estudados. Este escalonamento altera a

probabilidade de seleção e, portanto, de reprodução de cada um dos cromossomos dentro da população. Ou seja, altera-se a probabilidade de sobrevivência de cada um dos diferentes cromossomos durante todo o processo de evolução. A pressão seletiva pode também ser alterada em função da diversidade populacional a cada geração dos algoritmos genéticos. A figura 7.2 apresenta um exemplo de parametrização.

Figura 7.2 : Modificação da pressão seletiva pela parametrização dos alg. genéticos

Com a introdução do escalonamento, ocorre uma distinção entre função de aptidão (*fitness*) e função objetivo. A função de aptidão (*fitness*) é utilizada para a avaliação da saúde de cada cromossomo dentro da população, a cada geração dos algoritmos genéticos. Todos os cromossomos da população deverão também apresentar seus valores de forma parametrizada. A função objetivo representará a função do problema em análise em seu domínio real de valores.

Um exemplo de escalonamento entre função de aptidão (FA) e função objetivo (FO) é fornecida por (HOLLAND, 2000):

$$FA = \alpha.FO + \beta \text{ (equação 1)}$$

Os parâmetros α e β podem ser calculados dinamicamente a cada geração, por exemplo, através de um meta-algoritmo genético. Assim, estes parâmetros podem ser dimensionados de forma a controlar o número de cromossomos de melhor aptidão dentro da população.

7.4.2.4 Utilização de Técnicas Multimodais

Observou-se, durante a etapa de calibração dos algoritmos genéticos, principalmente para os algoritmos genéticos seqüenciais, que dentro das sessões em cada *set*, havia uma variação no valor de convergência da função objetivo. Uma possível justificativa é que a função objetivo, para o modelo de otimização de demanda, seja multimodal, podendo apresentar pontos de inflexão e, portanto, diversos pontos de máximos locais.

Este fato pode ser justificado se observado que os algoritmos genéticos não são projetados para encontrar diversos pontos de máximo simultaneamente (OLIVEIRA,

2001). Uma forma de amenizar este efeito é através da utilização de métodos denominados de nichos (*niching methods*) (FREGNI, 1997); (MAHFOUD, 1995) e (OLIVEIRA, 2001). Estes métodos procuram estender os algoritmos genéticos para domínios que requerem a localização e a manutenção de soluções múltiplas, impedindo a concentração da população em um único ponto. O objetivo final é manter a diversidade populacional, procurando encontrar a solução global (máximo global).

Uma outra técnica denominada de aglomeração (*crowding*), utiliza-se do conceito de similaridade entre indivíduos. Neste caso, elimina-se os indivíduos semelhantes da população, mantendo apenas o indivíduo similar mais promissor, ou seja, de maior aptidão. Outra técnica, denominada de aptidão compartilhada (*sharing fitness*), consiste na redução da aptidão de um indivíduo proporcionalmente ao número de indivíduos pertencentes ao mesmo nicho. Estas diversas técnicas poderão ser pesquisadas e inseridas no modelo de otimização de demanda proposto.

7.4.2.5 Utilização de Outras Classes de Algoritmos Genéticos Paralelos

Como pode ser observado no estudo de caso apresentado, um dos grandes problemas encontrado foi o elevado tempo e esforço computacional gasto na calibração dos algoritmos genéticos e no esforço de convergência em cada simulação.

Os algoritmos genéticos apresentam um grande paralelismo natural, motivo pelo qual muitos trabalhos vem sendo realizados na implementação de algoritmos genéticos em máquinas paralelas (JONG, 1999). Estas implementações apresentam o compromisso de procurar decrementar, significativamente, o tempo de execução dos algoritmos genéticos. Em futuras pesquisas podem ser aplicadas outras topologias de algoritmos genéticos paralelos, verificando se agregam melhorias adicionais aos resultados obtidos pelo modelo de otimização de demanda proposto. Algumas topologias relacionadas a algoritmos genéticos paralelos, podem ser encontradas em (ADAMIDIS, 1994); (ADAMIDIS, 1998); (ALBA; TROYA, 1998); (DUNCAN, 1990) e (PAZ, 1995a, 1996).

7.4.2.6 Reservatório dos Melhores Cromossomos

Podem ser pesquisadas diferentes topologias com algoritmos genéticos paralelos, para utilização no reservatório dos melhores cromossomos. Uma topologia a ser pesquisada

poderá conter uma ilha central (mestre) e diversas ilhas periféricas (escravas), que se comunicam com a ilha central. Diferentemente da topologia mestres escravo, apresentada no capítulo 4, todas as ilhas terão suas subpopulações e realizarão sua evolução independentemente. Após o processo de otimização em cada uma das ilhas periféricas, uma certa porcentagem de seus melhores cromossomos serão emigrados para uma ilha central, de capacidade populacional igual à soma dos cromossomos emigrados pelas ilhas periféricas.

Após o recebimento dos cromossomos imigrantes das ilhas periféricas, a ilha central, com uma população inicial já otimizada, iniciaria seu processo de evolução. O objetivo seria comprovar que a adoção deste reservatório inicial, com cromossomos já otimizados, permite um ganho adicional na otimização. Adicionalmente, poderiam-se realizar variações nesta topologia, por exemplo, analisando a influência da taxa de migração das ilhas periféricas para a ilha central. A figura 7.3 ilustra o procedimento de execução desta topologia a ser investigada.

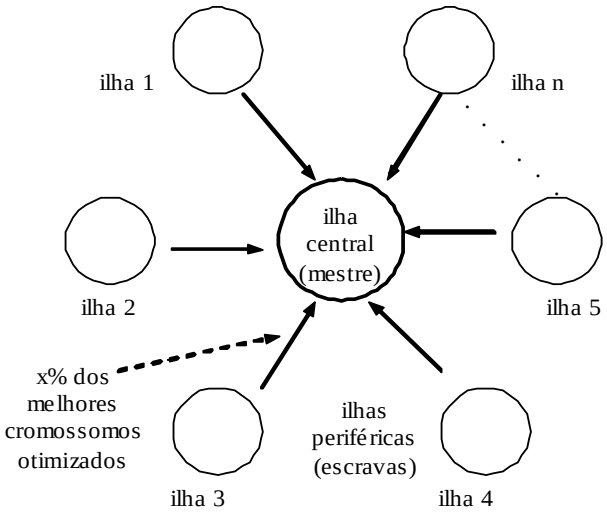

Figura 7.3: Topologia proposta e esquema de migração dos melhores cromossomos

7.4.2.7 Computação em Malha e Algoritmos Genéticos

Uma possível linha de pesquisa será a utilização da computação em malha (*Grid Computer*) (FOSTER; KESSELMAN; TUECKE, 2001) em conjunto com algoritmos genéticos, na solução do problema de otimização de demanda em infra-estrutura

aeronáutica. Neste caso, os algoritmos genéticos podem ser executados em uma rede de comunicação, com topologia de uma rede local ou de longa distância, semelhante a Internet. Esta rede de comunicação não necessitará estar dedicada a aplicação de otimização de demanda, podendo ser utilizada para outras aplicações, para melhor aproveitamento da infra-estrutura computacional disponível. O objetivo da pesquisa será verificar se as otimizações obtidas apresentam boa qualidade de convergência (se os resultados podem ser aplicadas no caso real), com sensível redução no tempo de convergência dos algoritmos genéticos, e na execução no tempo total de uma ou mais sessões.

7.4.2.8 Divisão em Problemas Menores

Uma alternativa de paralelismo que pode acelerar a velocidade de convergência dos algoritmos genéticos é dividir um problema complexo principal em diversas partes ou problemas de menor complexidade. Neste caso, seria adotado um algoritmo genético paralelo em ilhas, em que a cada ilha, seria atribuído um destes problemas menores para serem resolvidos.

A principal questão seria em como dividir ou particionar este problema principal, de tal forma que cada parte seja significativamente menor (problema menor), e simultaneamente guarde as propriedades essenciais do problema principal, de forma a contribuir para a sua solução (FREGNI, 1997). Uma alternativa seria dividir o problema principal em módulos ou partes que apresentem o menor acoplamento possível de informações entre as suas partes, de forma a não aumentar demasiadamente a troca de informações entre ilhas, prejudicial à velocidade de otimização.

7.4.2.9 Utilização de Técnicas Híbridas

Existem algumas linhas de pesquisas apresentadas em (CORDÓN; HERRERA, 1997); (JONG, 1999); (SCHAFFER; WHITLEY; ESHELMAN, 1992) e denominadas de algoritmos genéticos híbridos (*hybrid genetic algoritms*) que procuram complementar os algoritmos genéticos com outras técnicas. Por exemplo, através de técnicas como as redes neurais artificiais e a lógica *fuzzy*. Estas técnicas podem ser utilizadas na modelagem de um dado problema, e os algoritmos genéticos podem auxiliar na otimização de alguns parâmetros desta modelagem.

Especificamente, na pesquisa relacionada ao problema de otimização de demanda em infra-estrutura aeronáutica, poder-se-ia utilizar a lógica *fuzzy* para modelar os patamares de excesso de demanda definidos como congestionado, saturado aceitável e supersaturado, utilizados na otimização pela função objetivo. A figura 7.4 apresenta os critérios de decisão para estes patamares de demanda.

Diagrama de análise de situação

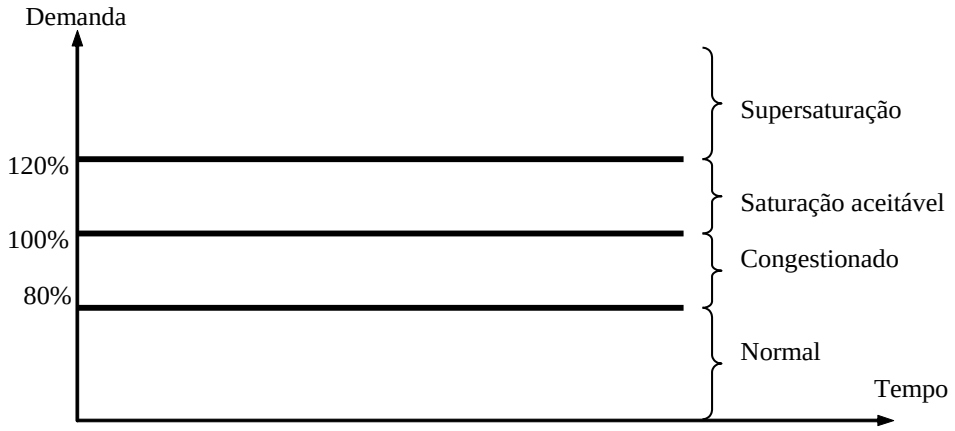

Figura 7.4: Diagrama de análise de estado e definição de variáveis lingüísticas

Poderão ser utilizadas as seguintes variáveis lingüísticas de entrada:

- Normal: demanda abaixo de 80% da capacidade nominal declarada do setor.
- Congestionado: demanda entre 80% e 100% da capacidade nominal declarada do setor.
- Saturação aceitável: demanda entre 100% e 120% da capacidade nominal declarada do setor.
- Supersaturação: demanda está acima de 120% da capacidade nominal declarada do setor.

Tratamento similar poderá ser realizado para outros parâmetros, tais como, para a capacidade nominal declarada dos setores, atrasos em aeroportos, janelas de tempo em setores e, atrasos e adiantamento de entrada de vôos externos. Os mesmos não apresentam também precisão em seus valores assumidos dentro do problema de otimização de demanda estudado. Estes valores podem assumir uma certa variação em seus valores podendo, portanto, serem modelados pela lógica *fuzzy*.

7.4.2.10 Utilização de Técnicas de Otimização Heurísticas

Podem ser utilizadas outras técnicas de otimização através de procura heurística para o problema de otimização de demanda em infra-estrutura aeronáutica. Algumas técnicas a serem investigadas são: algoritmo de busca gulosa (*greedy*), *backtracking*, *branch & bound*, programação dinâmica (*dynamic programming*), Encosta ascendente (Hill clinbimg), Têmpera simulada (Simulated annealing) entre outras. Um melhor detalhamento destes e outros algoritmos pode ser visto em (CAWSEY, 1998); (CROOK, 2001); (FREGNI, 1997); (GREENBERG, 2001); (ICS 161, 2002); (LUBY; SINCLAIR; ZUCKERMAN, 1993); (JOGOTA, 2002); (KNOTT, 1997) e (WANG; MACIEJEWSKI; SIEGEL, 1998).

No capítulo 8 são apresentadas as principais conclusões e contribuições deste trabalho de pesquisa, bem como um resumo das futuras linhas de pesquisas que podem ser desenvolvidas.

Neste capítulo é apresentada as principais conclusões e contribuições deste trabalho de pesquisa, bem como um resumo das futuras linhas de pesquisa.

8 CONCLUSÕES E CONTRIBUIÇÕES

"O espírito científico é estar, sobretudo, numa busca permanente da verdade, com consciência da necessidade dessa busca, expondo as suas hipóteses à constante crítica, livre de crenças e interesses pessoais, conclusões precipitadas e preconceitos."

Espírito Científico,
Francisco Saiz, Sociedade dos Cientistas Mortos, 2000

São apresentadas nesse capítulo as principais conclusões e contribuições desse trabalho de pesquisa. Em seguida, são destacadas as principais futuras linhas de pesquisa. Dessa forma, esse capítulo procura sintetizar as diversas reflexões apresentadas detalhadamente no capítulo anterior.

8.1. Conclusões e Contribuições

Esse trabalho de pesquisa chegou a conclusões e contribuições que podem ser dividas em duas grandes áreas do conhecimento: Sistemas Aeronáuticos e Inteligência Artificial.

8.1.1. Área de Sistemas Aeronáuticos

O modelo de otimização de demanda proposto mostrou-se efetivo para o processo de otimização de uma demanda de tráfego aéreo em uma infra-estrutura aeronáutica previamente conhecida. O objetivo de reduzir a carga de trabalho de gerenciamento a patamares considerados como suportáveis em todos os setores da infra-estrutura aeronáutica estudada foi alcançado. Desta forma, os Controladores de Tráfego Aéreo são submetidos a uma menor carga de trabalho, permitindo a manutenção dos níveis de segurança em níveis aceitáveis.

No estudo de caso foi verificado que, com uma alteração de 2% na demanda original, o tempo de otimização foi praticamente igual à metade do tempo da demanda original.

Observou-se também, pelo estudo de caso, que certos parâmetros do modelo de otimização proposto apresentam maior influência na carga de trabalho de gerenciamento. Estes parâmetros são: atrasos nos demais aeroportos (Belo Horizonte e Brasília) e atrasos e adiantamentos de entradas dos vôos externos no cenário aeronáutico considerado. Conclui-se também que, pequenas flexibilizações simultâneas em diferentes janelas de tempo podem apresentar melhores resultados, em termos de carga de trabalho global, quando comparada a flexibilizações maiores em um único tipo de janela de tempo.

Dessa forma, o modelo de otimização proposto pode ser visto como uma poderosa ferramenta de auxílio na utilização mais racional da infra-estrutura aeronáutica existente podendo ser utilizada, em breve, nas fases de planejamento estratégico e pré-tático do fluxo do tráfego aéreo.

8.1.2. Área de Inteligência Artificial

Pelo processo de calibração dos algoritmos genéticos observou-se que eles consomem grande quantidade de recursos computacionais e tempo de simulação.

O algoritmo genético método de seleção por torneio apresentou os melhores resultados (menor carga de trabalho global) em todos os estudos realizados, tanto para os algoritmos genéticos seqüências quanto para os paralelos. Dessa forma, o algoritmo genético seleção por torneio pode ser considerado o mais apto a ser utilizado no problema de otimização de demanda da infra-estrutura aeronáutica.

Observou-se que, de forma geral, tamanhos populacionais maiores apresentaram melhores otimizações. O inconveniente é que o tempo de otimização aumenta de forma significativa com o crescimento populacional. Para o algoritmo genético evolução por abelha rainha este crescimento de tempo de otimização foi menor entre todos os algoritmos genéticos estudados (roleta, torneio e abelha rainha).

O operador mutação apresentou a maior influência no modelo de otimização de demanda proposto. Este fato é justificado principalmente na adoção de mais de um ponto de mutação simultâneos, bem como na utilização de taxas elevadas de mutação nos melhores sets dos algoritmos genéticos estudados.

A adoção de 5 (cinco) pontos de mutação simultâneos desde o início de processo de otimização trouxe melhores resultados quando comparado com apenas 1 (um) ponto de mutação.

Da mesma forma, a adoção de 2 (dois) pontos de estabilidade para o critério de parada, sendo o primeiro com 5 (cinco) pontos de mutação simultâneos, e o segundo com apenas 1 (um) ponto de mutação, resultou num ganho quanto à qualidade dos resultados da otimização em relação à adoção de apenas 1 (um) ponto de estabilidade.

O algoritmo genético evolução por abelha rainha apresentou resultados inferiores quanto à qualidade dos resultados da otimização, quando com parado aos algoritmos genéticos método de seleção por roleta e torneio. Entretanto, ele apresenta, como característica relevante, um tempo de otimização significativamente inferior aos demais algoritmos genéticos.

Observou-se também que a adoção da técnica de utilizar um reservatório dos melhores cromossomos obtidos em otimizações anteriores, provocou um ganho significativo na qualidade dos resultados da otimização. Uma possível justificativa é que construindo-se reservatórios dos melhores cromossomos, obtém-se populações com grande número de blocos construtivos (building blocks). Adicionalmente notou-se uma significativa redução no tempo de otimização, quando comparada às otimizações com populações inicias aleatórias.

8.2. Sugestões de Linhas de Pesquisa

São listadas a seguir algumas linhas de pesquisa que merecem ser abordadas em futuros trabalhos.

8.2.1. Área de Sistemas Aeronáuticos

Dentro da área de gerenciamento de tráfego aéreo existem diversas possibilidades que podem ser pesquisadas com o objetivo de aperfeiçoar o modelo de otimização de demanda em infra-estrutura aeronáutica.

a) Inclusão de Vôos com Escala e com Pólos Concentradores de Tráfego

As rotas dos vôos, dentro deste trabalho, foram consideradas somente como diretas, sem considerar aeroportos intermediários entre o aeroporto origem e destino em cada rota.

Em um cenário aeronáutico poderão ser considerados vôos com escala e com pólos concentradores de tráfego.

b) Inclusão de Vôos não RPL

No cenário aeronáutico os vôos não repetitivos (alternativos e autônomos) podem ser considerados futuramente no modelo de otimização de demanda.

c) Incorporação de Novos Cenários Aeronáuticos

O modelo de otimização de demanda é flexível, podendo acomodar novas infra-estruturas de menores ou maiores dimensões ao analisado nessa pesquisa.

d) Incorporação de outros Fatores na Otimização

Outros parâmetros, tais como, atrasos em aeroportos e setores de espaço aéreo, bem como custos hipotéticos poderão ser considerados no processo de otimização.

e) Adoção de Carga de Trabalho de Gerenciamento mais Realística

Futuros trabalhos de pesquisa poderão realizar uma análise mais precisa e criteriosa da carga de trabalho de gerenciamento, principalmente relacionando-a com a carga de trabalho mental dos Controladores de Tráfego Aéreo.

f) Incoporação de otimizaçõeos em aeroportos

Poderá ser estudado e incluso no modelo de otimização de demanda em infra-estrutura aeronáutica otimizações internas aos aeroportos, podendo estas serem também incorporadas na função objetivo.

g) Integração com Outros Sistemas Aeronáuticos

O modelo de otimização de demanda em infra-estrutura aeronáutica deve ser acoplado a outras aplicações que apresentam o objetivo de auxiliar na obtenção de um melhor balanceamento entre a capacidade e demanda. Assim, o modelo de otimização de demanda dentro do contexto do Gerenciamento de Fluxo de Tráfego Aéreo pode integragir com diversas outras ferramentas.

h) Integração dentro do Contexto CNS/ATM

Dentro deste contexto, o modelo de otimização de demanda deve ser pesquisado e integrado no balanceamento entre capacidade e demanda no ambiente CNS/ATM.

8.2.2. Área de Inteligência Artificial

Dentro da perspectiva de Inteligência Artificial, mais especificamente algoritmos genéticos, existem diversas possibilidades de pesquisa visando aprimorar o modelo de otimização de demanda proposto. A seguir essas linhas futuras de pesquisa são listadas.

a) Utilização de Meta Algoritmos Genéticos

Uma alternativa a ser investigada procurando evitar o excessivo esforço de calibração é através da utilização de um meta-algoritmo genético acoplado ao algoritmo genético principal, com o objetivo de encontrar o conjunto de parâmetros internos que sejam mais adequados a este algoritmo genético principal.

b) Refinamento dos Algoritmos Genéticos Estudados

Realização de pesquisas que permitam uma análise ainda mais profunda e detalhada de alguns aspectos não cobertos por esse trabalho de pesquisa.

c) Aperfeiçoamento dos Métodos de Otimização

Uma forma de estudar a diminuição do tempo de otimização é através da pesquisa da pressão seletiva.

d) Utilização de Técnicas Multimodais

Uma forma provável de amenizar a dificuldade de encontrar diversos pontos de máximo simultaneamente seja através da utilização de métodos denominados de nichos (niching methods) ou de aglomeração (crowding).

e) Utilização de Outras Classes de Algoritmos Genéticos Paralelos

Em futuras pesquisas podem ser aplicadas outras topologias de algoritmos genéticos paralelos, verificando se agregam melhorias adicionais aos resultados obtidos pelo modelo de otimização de demanda proposto.

f) Reservatório dos Melhores Cromossomos

Podem ser pesquisadas diferentes topologias com algoritmos genéticos paralelos, para utilização no reservatório dos melhores cromossomos.

g) Computação em Malha e Algoritmo Genéticos

Uma possível linha de pesquisa será a utilização da computação em malha (Grid Computer) em conjunto com algoritmos genéticos, na solução do problema de

otimização de demanda em infra-estrutura aeronáutica visando uma boa qualidade de convergência com sensível redução no tempo de processamento.

h) Divisão em Problemas Menores

Uma alternativa para acelerar a velocidade de convergência seja dividir o problema complexo principal em diversas partes ou problemas de menor complexidade. Nesse caso, seria adotado um algoritmo genético paralelo em ilhas, em que a cada ilha, seria atribuído um destes problemas menores para serem resolvidos.

i) Utilização de Técnicas Híbridas

Pesquisa em algoritmos genéticos híbridos visando uma maior otimização de alguns parâmetros do modelo proposto. Esses algoritmos híbridos procuram complementar os algoritmos genéticos com técnicas de redes neurais e lógica fuzzy.

j) Utilização de Técnicas de Otimização Heurística

Podem ser utilizadas outras técnicas de otimização através de procura heurística para o problema de otimização de demanda em infra-estrutura aeronáutica.

Apresenta as referências bibliográficas utilizadas neste trabalho de pesquisa.

REFERÊNCIAS

ABU-GHAZALEH, N. B.; WISLEY, P. A. **A Shared control parallel architecture model**. Cincinnati: Computer Architecture Design Laboratory, Department ECECS, University of Cincinnati, 1996.

ADAMIDIS P. **Review of parallel genetic algorithms bibliography**. Thessaloniki: Faculty of Engineering, Aristotle University of Thessaloniki, Greece, Version 1, November 1994.

ADAMIDIS P., **Parallel evolutionary algorithms:** a review. Thessaloniki: Department of Applied Informatics, University of Macedonia, 1998.

ADVANCES IN COMPLEX SYSTEMS. A Multiciplinary Quarterly Journal. Published by HERMES Science Publications, World Scientific. Disponível em http://www.tbi.univie.ac.at/ACS. Acesso em 14/02/2003.

ALBA, E.; TROYA, J. M. Málaga: **A Survey of parallel distributed genetic algorithms**. Depto. De Lenguejes, Universidad de Málaga, 1998.

ANGLO. **Apostila biologia e genética**. Anglo Latino, 1990.

ATHENES, S.; AVERTY, P.; PUECHMOREI, S.; DELAHAYE, D.; COLLET, C. **ATC Complexity and controller workload: trying bridge the gap**. CENA, ENAC, Toulouse Cédex, 2002.

BANZHAF, W.; REEVES, C. **Foundations of genetic algorithms 5**. Morgan Kaufmann Publishers, 1999.

BAR, Y.Y. **Dynamics of complex systems.** The Advanced book program, Perseus Books, Reading, Massachusetts, 1997.

BAR, Y.Y. **Unifying principles in complex systems**. Cambridge: New England Complex Systems Institute, 2002.

BENNET, A. P. **Modeling evolving populations**. Southampton: University of Southampton, 2000. Disponível em http://www.isis.ecs.soton.ac.uk/isystems/evolutionary/ notes/evol/. Acesso em 21/04/2003.

BLANC, M. **Os herdeiros de Darwin**. Editora Scritta, 1994.

BODENHOFER, U. **Genetic algorithms: Theory and applications**. Linz-Hagenberg: Lecture Notes, Third Edition, Winter 2004, Fuzzy Logic Laboratorium Linz-Hagenberg, 2004.

BRANCO, K. R. L. J. C. **Índice de carga de desempenho em ambientes paralelos/distribuídos - Modelagem e métricas**. São Carlos: Instituto de Ciências Matemáticas de São Carlos, Universidade de São Paulo, 2001.

Civil Air Navigation Services Organization, CANSO, Group. **DEMYSTIFYING CNS/ATM**, Report Final Version (June 1999).

CAWSEY, A. **Greedy algorithms**. Disponível em http://www.cee.hw.ac.uk/~alison/ds98/node121.html. Acesso em 19/06/2003.

CONTROLE DE VOO. Disponível em http://www.controledevoo.hpg.ig.com.br. Acesso em 14/09/2003.

COELHO, C.A.C. **A Survey of constraint handling evolutionary algorithms**. Vera Cruz: Laboratório Nacional de Informática Avanzada, 1998.

CORDÓN, O.; HERRERA, F. **A general study on genetic fuzzy systems**. Granada: Universidade de Granada, John Wiley & Sons Ltd., pp.35-57, 1997.

CORREA, M. A. **CDM " Collaborative decision making" na gestão do tráfego aéreo**. São Paulo: II-Seminário de Pesquisa do Grupo de Análise de Segurança, Grupo de Análise de Segurança, 2004.

CORTES, O. A. C.; SAAVEDRA, O. R.; PEREIRA. R.S. **Resolução de problemas de otimização multimodal através de estratégias evolutivas paralelas**. Santiago: XIV Congresso Chileno de Engenharia Elétrica, Universidade Católica do Chile,2001.

CRAIGHURST S.; MARTIN, W. **Enhancing genetic algorithm Performance Trough Crossover Prohibitions Based on Ancestry**. In: CONFERENCE ON GENETIC ALGORITHMS,6. **Proceedings.** Morgan Kaufmann, San Mateo, 1995.

CROOK J. **Dynamic programming**. Catalase WebSite, 2001. Disponível em http://www.catalase.com/dprog.htm. Acesso em 10/01/2003.

CS 267. **Parallel computers architectures**, University California Berkeley, 1999. Disponível em http://www.cs.berkeley.edu/~demmel/cs267_Spr99/1999. Acesso em 14/10/2003.

CS5513. **Parallel computer architectures**. San Antonio: Department of Computer Science, Chapter 8. Disponível em www.cs.utsa.edu/faculty/boppana/5513, 2000. Acesso em 15/06/2004.

DAVIDSON, A.; TEICHER, M. H.; BAR, Y. B. **The role of environmental complexity in the well being of the elderly**. Londres: Complexity and Chaos in Nursing, 1997.

DECRETO LEI Nº 32-1966. **Código brasileiro do ar**. Disponível em http://www.lei.adv.br/32-66.htm, 18/ 11/ 2003. Acesso em 12/04/2004.

DALAHAYE D. **Optimization de la sectorization de l'espace aérien par algorithmes génétiques**. Doctorat, Doctorat Informatique ENSAE (Ecole Nationale de la Statistique et de I'Administration Economique), CENA (Centre d'Etudes de la Navigation Aérienne), 1995.

DUNCAN R. A Survey of parallel computer architectures. **Control Data Corporation**, IEEE Computer, February, 1990.

EATM. **MOde S Programme, Mode-S implementation in Europe, information notice for military organizations**. Eurocontrol ATM 2000+ Strategy, EATM-European Air Traffic Management, October 2003.

ECE 669. **Advanced computer architecture II**. Massachusetts: University of Massachusetts. Disponível em www.ecs.umass.edu/ece/tessier/courses/669/lec01.ps, 2000. Acesso em 02/03/2003.

ETAPA. **Apostila de biologia**. Curso pré-vestibular Etapa, 1991.

FALKENAUER, E. **Genetic algorithms and grouping problems**. John Wiley & Sons, 1999.

FCO.ET1.ST07.DEL02. **ATM Strategy for 2000+**. European Organization for the safety of Air Navigation, Eurocontrol, Volume 2, Issue 2.0, 1 May 1998.

FOSTER, I.; KESSELMAN, C.; TUECKE, S. **The Anatomy of the grid, enabling scale virtual organizations**. Chicago: Mathematics and Computer Science Division, Department of Computer Science, University of Chicago, 2001.

FREGNI, E. **Arquitetura híbrida na solução do problema de escalação da manufatura**. 213 páginas. Tese (Doutorado), Departamento de Computação e Sistemas, Escola Politécnica, Universidade de São Paulo, 1997.

FOX, G.C.; CODDINGTON, P.D. **Parallel Computers and complex systems**. Syracuse: Northeast Parallel Architectures Center, Syracuse University, NY 13244, 1994.

GEHRINGER, E. F.; KENNY, G. Q. **Architeture of parallel computers**. Summer, Intro & Overview, 1999.

GREENBERG, H. J. **Greedy algorithms**. Denver: University of Colorado at Denver, March, 2001.

GEN, M.; CHENG, R. **A survey of penalty tecbhiniques in genetic algorithms**. Ashikaga: Ashikaga Institute of Technology, Japan, 1996.

GOLDBERG, D. E.; RICHARDSON, J. **Genetic algorithms with sharing for multimodal function optimization**. In: INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS, 2. **Proceedings**, Lawrence Erlbaum., N.J, editado por J. Grefenstette, Massachusetts Institute of Technology, 1987.

GORDON, V.S.; WHTLEY, D. **Serial and parallel genetic algorithms as function optimizers**. Fort Collins: Colorado, Colorado State University, Department of Computer Science, 1996.

GRÜNINGER, T.; WALLACE, D. **Multi-modal optimization using genetic algorithms**. Technical report, NSF CIPD Technical report, 1996. Disponível em http://cadlab.mit.edu/publications/96-senin -tr9602-ga/abstract.html. Acessso em 12/05/2003.

HÄMÄLÄINEN, T. **Implementation and algorithms of a tree shape parallel computer**. Tampere: Tampere University of Technology, December, 1996.

HÄNDLER, W. **Classification of parallel computer architectures: SIMD**. Erlangen-Nürnberg: Department of Computer Architecture, University of Erlangen-Nürnberg, 2000. Disponível em http://www3.informatik.uni-erlangen.de/Lectures/AHPC/SS2001/Skript/. Acesso em 14/09/2002.

HAUPT, R. L.; HAUPT, S. E. **Practical genetic algorithms**. Canada: John Wiley & Sons , 1998.

HOLLAND, J. H. **"Outline for a logical theory of adaptive systems"**. Massachusetts: Association Computer Machine, volume 3, pages 297-314, November 1961.

HOLLAND, J. **Adaptation in natural and artificial systems**. Massachusetts: MIT Press, 1992.

HOLLAND, J. C. **Algoritmos genéticos adaptativos:** Um estudo comparativo. 143 páginas. 07/04/2000. Dissertação, Escola Politécnica da Universidade de São Paulo, São Paulo, 2000.

HUTCHIND, E. **Cognition in the wild**. Cambridge: MIT Press, 1995.

INTERNATIONAL CIVIL AVIATION ORGANIZATION, **ICAO 9426**. Air Traffic Services Planning Manual, Montreal, 1st edition (provisional), 1984. Reprinted August 2002, incorporating Amendments 1-4.

ICS 161-02. **The fibonacci numbers**. Berlin: Department & Computer Science, Irvine, May 2002.

International Civil Aviation Organization. **ICAO 9426-02**. Air traffic services planning manual. doc 9426, Montreal, 1st edition (provisional), 1984, incorporating Amendments 1-4, reprinted August 2002**.**

ICAO, DOC 9426, **Air Traffic Services Planning Manual**, Montreal, 1st edition (provisional), 1984. Reprinted August 2002,incorporating Amendments 1-4.

IDG NEWS SERVICE STORY. **Compaq builds supercomputers for genomics research**. Disponível em www.idg.net/idgns/2001/01/19/ CompaqBuildsSupercomputerForGenomicsRese.shtml, 2001. Acesso em 20/07/2004.

Instrução do Ministério da Aeronáutica. **IMA 100-12**. Regras do ar e serviço de tráfego aéreo: IMA 100-12, Regras para serviços de tráfego aéreo, Rio de Janeiro, 1999.

IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION. Disponível em http://www.ieee-nns.org/pubs/tec/, 2004. Acesso em 14/07/2003.

INFRAERO. **Missão**. Infraero Aeroportos Brasileiros. Disponível em http://www.infraero.gov.br, 11/10/2003. Acesso em 10/04/2004.

INTERNATIONAL CONFERENCE PPSN, **8. International conference on parallel problem solving from nature (PPSN)**. Disponível em http://events.cs.bham.ac.uk/ppsn04/, Birmingham, UK. Acesso em 04/03/2004.

ITANI, A. **Condições de saúde e trabalho dos Controladores de Tráfego Aéreo**. UNESP, Universidade Estadual Paulista, 2003.

JOGOTA, A. **Multilayer perceptions, kohonen maps, kohonen Networks**. European Southern Observation (ESO), 2002.

JONG, K. D. **Genetic algorithms:** a 30 year perspective. Virginia: Computer Science Department, George Mason University, 1999.

JUNG, S. H. **Queen-bee evolution for genetic algorithms**. Electronics Letters, 20th March 2003, vol. 39, No.6, 2003.

KNOEZER, D. **Perspectives for the future, looking towards the challenges of the 21st century**. DG Research – Aeronautics, Dayton, European Commission Research, July 2003.

KNOTT, R. Fibonacci's algorithm. **Horodam in Australian Mathematics Teacher**, volume 31, pages 123-134, 1997.

KOTSIS, G. **Interconnection topologies and routing for parallel processing systems**. Tese doutorado, Institut f"ur Angewandte Informatik, University at Wien, Austria, 1992.

KUYPER, I. S., **Introduction evolutionary computation**. Maastricht: Curse Machine Learning, Universiteit Maastricht, Faculty of General Sciences, Department of Computer Science, February 2000.

LINHARES, S.; GEWANDSZNAJDER, F. **Ecologia**. São Paulo: Editora Ética, 1980.

LINHARES, S.; GEWANDSZNAJDER, F**. Biologia hoje, genética, evolução e ecologia**. São Paulo: Editora Ética, 1998.

LOZITO, S.; MCGANN, A.; MACKIONTOSK, M. A. **Free flight and self-separation from flight deck perspective**. San Jose: NASA Ames Research Center, San Jose State University, 1999.

LUBY, M.; SINCLAIR, A.; ZUCKERMAN D. **Optimal speedup of Las Vegas algorithms**. SYMPOSIUM ON THEORY OF COMPUTIONG AND SYSTEMS,2 **Proceedings**. Jerusalem, 1993.

LUTFARTSVERKET. **Swedish civil aviation**. Administration, Sweden, AIC, november, 2001.

MAHFOULD, S. W. **Niching methods for genetic algorithms**. PhD Thesis, University of Illinois at Urbana – Champaign, IlliGAL Report Nº 95001,1995.

MARKS, R. **Intelligence:** computational versus artificial. IEEE Transactions on Neural Networks, v. 4, n. 5, Sep. 1993.

MICHALEWICZ, Z.,; REYNOLDS, R.; FOGEL, D**. A survey of constraint handling techniques in evolutionary computation methods**. In: ANNUAL CONFERENCE ON EVOLUCIOTIONARY PROGRAMMING, 4 .**Proceedings**. pages 135-155, 1995.

MURRAY, R.S. **Estatística**. Paris: Polytechnic Institute, Coleção Schaum Ao Livro Técnico, Rio, 1969.

NAUFAL, J. K. **Algoritmo e arquitetura para a localização de falhas em sistemas distribuídos**. 30/05/2000.215 páginas. Dissertação, Escola Politécnica da Universidade de São Paulo, 2000.

NATIONAL INSTITUTE OF MENTAL HEAKTH. **Learning and the brain**. National Institute of Mental Heakth, NIH, , 1994. Disponível em http://www.edupr.com/brain4.html. Acesso em 02/05/2004.

NIMH, National Training Program. **Complex systems and brain sciencs**. Florida: Florida Atlantic University, 2000.

NOWOSTAWSKI, M.; POLI, R. **Parallel genetic algorithm taxonomy**. Otago: Information Science Department, University of Otago, Dunedin, New Zealand, School of Computer Science, The University of Birmingham, May, 1999.

OLIVEIRA, P.L.N. **Estatística**. São Paulo: Escola de Engenharia Mauá, Escola de Administração da Empresa de São Paulo, Editora Edgard Blücher Ltda, 1997.

OLIVEIRA, A. C. M. **Algoritmos evolutivos para problemas de otimização numérica com variáveis reais**. São José dos Campos: Monografia apresentada para o Exame de Qualificação do Curso de Computação Aplicada – CAP, INPE – Instituto Nacional de Pesquisas Espaciais, 2001.

OLIVEIRA, I. R. **Verificação de segurança em confluência de trajetórias de aeronaves utilizando autômatos híbridos**. 10/07/2003. 116 páginas. Dissertação, Departamento de Computação e Sistemas Digitais, Escola Politécnica, Universidade de São Paulo, São Paulo, 2003.

PACHECO, M. A. C. **Algoritmos genéticos: princípios e aplicações**. Rio de Janeiro: Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, 1998.

PATRIDGE, D.; WILKS, Y. **The foundations of artificial intelligence:** a sourcebook. Cambridge University Press, 1990.

PAZ, E. C. **Efficient parallel genetic algorithms: theory and practice**. IIIinois: Department of Computer Science, University of IIIinois at Urbana-Champaign, 1994.

PAZ, E. C. **A Summary of research on parallel genetic algorithms**. IIIiGAL Report N° 95007, Department of Computer Science, University of IIIinois at Urbana-Champaign, 1995a.

PAZ, E. C. **A survey of parallel genetic algorithms**. Department of Computer Science, University of IIIinois at Urbana-Champaign, 1996.

PAZ, PAZ E.C. **Efficient and accurate parallel genetic algorithms**. Lawrence: Livermore National Lab, U.S.A., Klumar Academic Publishers, 2000.

RAD, Route Availability Document. **Navegação aérea de Portugal**. Direcção de Segurança e Desempenho Operacional, Aeronautical Information Service, fevereiro, 2003.

RAUBER, T.; REILEIN, R.; RÜNGER, G. **Orthogonal processor groups for message-passing programs**. Institut für Informatik, Universität Halle-Wittenberg, Technische Universität Chemn itz, Germany, 2001.

RENTEX, J. L. **ATC Capacity assessment & monitoring**. Capacity Enhancement Manager, Eurocontrol, 1998.

RICHARDSON, J; PALMER M.; LIEPINS G.; HILLIARD M. **Some guidelines for genetic algorithms with penalty functions**. INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS, 3. **Proceedings**. pages 191-197, 1989.

SCHAFFER, J. D.; WHITLEY D.; ESHELMAN L. J. **Combinations of genetic algorithms and neural networks**. IEEE, Computing Neural ,1992.

SCHOFIELD, J. **Airbus global market forecast**. Washington DC: Aviation Forecast Conference, Airbus Industrie of North America, March 7-8, 2000

SCHREIBER, G.; WIELINGA B.; BREUKER J. **KADS - A Principled approach to knowledge-based system development**. Netherlands: Knowledge-Based Systems, Volume 11, University of Amsterdam, Academic Press, 1993

SCHWEFEL, H. P.; HAMMEL U.; BÄCK T. **Evolutionary computation:** comments on the history and current state. IEEE Transactions on Evolutionary Computation, Vol. 1, N° 1, April 1997.

SILVEIRA, J. A. **Transporte aéreo regular no Brasil: Análise econômica e função custo**. Tese (Doutorado), Engenharia de Transporte Aéreo, COPPE/UFRJ, Universidade Federal do Rio de Janeiro, 2003.

SHORROCKS, B**. A Origem da diversidade as bases genéticas da evolução**. São Paulo: T.A. Queiroz Editor, Editora da Universidade de São Paulo, 1978.

SIEWERDT, E. **Curso AUT-ATFM**. Luxembourg: Instituto de Navegação Aérea da EUROCONTROL, 1991.

SIEWERDT, E. **Sistemas de controle de tráfego aéreo brasileiro**. São Paulo: Atech Tecnologias Críticas, Apresentação realizada na Escola Politécnica da Universidade de São Paulo, complemento a Disciplina Confiabilidade e Disponibilidade de Sistemnas, Universidade de São Paulo, 2002.

SIEWERDT, E., Publicação eletrônica [mensagem pessoal], mensagem recebida por: <jamilkn@hotmail.com.br> em 25 junho de 2003.

SIEWERDT, E., Publicação eletrônica [mensagem pessoal], mensagem recebida por <jamilkn@hotmail.com.br> em 01 julho de 2003a.

SIEWERDT, E. **Safety-critical systems in air traffic management**. São Paulo: Atech Tecnologias Críticas, apresentação realizada na First Latin American Symposium on Dependable Computing LADC, Universidade de São Paulo, 2003b.

TARGA, D.; ALVES, C. J. P.; ARAUJO, M. J. M. **Uma ferramenta automatizada de auxílio à alocação de slots para o problema de gerenciamento de fluxo de tráfego aéreo**. São Paulo: Divisão de Engenharia de Infra-Estrutura Aeronáutica, Departamento de Transporte Aéreo, Instituto de Tecnlógico de Aeronáutica, Fundação Aplicações de Tecnologias Críticas – ATECH, 2001.

THE FLYING CIRCUS. **Models for the parallelization of genetic algorithms**. On-line Tutorial. Disponível em http://www.liacs.nl/~gusz/Flying_Circus/1.Reading/2.Tutorial/04/. Acesso em 06/07/2002.

TOMASSINI, M. **Evolutionary algorithms**. Lausanne: Logic Systems Laboratory, Swiss federal Institute of Tecnology, Switzerland, 1996.

TOMLIN, C.; PAPPAS, G. J.: SASTRY, S. **Conflict resolution for air traffic management:** a study in multiagent hybrid systems. IEEE Transactions on Automatic Control, vol.43, no. 4, April 1996.

UNDERSTANDING TCP/IP. **Self Study and Technical Reference Manual**. 3COM, 1991.

VAVAK, F.; FORGARTY, T.C. **A Comparative study of steady state and generational genetic algorithms for use in nonstationary environments**. Bristol: Faculty of Computer Studies and Mathematics, University of the West of England, 1995.

VERLHAC, C. **Optimization of opening schemes**. Versailles: 4th ATM R&D Seminar, Euro control Experimental Center, 2001.

WANG, J. **Dynamic programming algorithms for global and local sequence alignment**. Cambridge: The University of Cambridge, 1997.

WANG, L.; MACIEJEWSKI, A.; SIEGEL, H. J., ROYCHOWDHURY V. P. **A Comparative study of five parallel genetic algorithms using the traveling salesman problem**. Los Angeles: Microsoft Corporation, Redmond, Electrical Engineering Department, UCLA, 1998.

WHITLEY, D. J.; BEVERIDGE, J. R.; SALVEDO, C.G; GRAVES, C. **Messy genetic algorithms for subset feature selection**. Colorado: Department of Computer Science, Colorado State University, Fort Collins, 1998.

ZADEH, L.A. **Soft computing and fuzzy logic**. California: University of California at Berkley, IEEE Software, November,1994.

ZADEH, L.A. **The roles of soft computing and fuzzy logic in the conception**. California: Report Supported in part by NASA Grant NCC 2-275and the BISC Program, Design and Deployment of Intelligent Systems, Department EECS, University of California, 1997.

ZWEBEN, M.; FOX, M. S. **Intelligent scheduling**. San Francisco: Morgan Kaufmann Publishers, 1994.