



UNIVERSIDADE FEDERAL DO CEARÁ
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

César Lincoln Cavalcante Mattos

**Aplicação de Algoritmos de Otimização
Metaheurística para Gerência de Recursos de Rádio**

FORTALEZA – CEARÁ
DEZEMBRO 2009

CÉSAR LINCOLN CAVALCANTE MATTOS

Aplicação de Algoritmos de Otimização Metaheurística para Gerência de Recursos de Rádio

*Monografia de Conclusão de Curso
apresentada à Coordenação do Curso
de Graduação em Engenharia de
Teleinformática da Universidade
Federal do Ceará como parte dos
requisitos para obtenção do grau de
Engenheiro de Teleinformática.*

Área de Concentração: Inteligência
Computacional Aplicada

Orientador : Prof. Dr. Guilherme de
Alencar Barreto

Co-orientador : Prof. Dr. Francisco
Rodrigo Porto Cavalcanti

FORTALEZA – CEARÁ
DEZEMBRO 2009

Resumo

Neste trabalho é realizada uma análise do problema de gerência de recursos de rádio em sistemas com capacidade limitada por interferência, tais como o sistema WCDMA. Detalha-se um modelo econômico de alocação de recursos que considera a utilidade do serviço fornecido, a probabilidade de aceitação do serviço pelos usuários e a receita gerada para a operadora. Estuda-se um modelo de otimização com restrições para o problema, enquanto uma técnica metaheurística híbrida baseada em *Particles Swarm Optimization* (PSO) e *Simulated Annealing* (SA) é utilizada para buscar soluções aproximadas. Os resultados obtidos com simulações desenvolvidas no software Scilab indicam que a abordagem proposta é capaz de prover soluções factíveis para o problema a partir de pouca informação inicial.

Palavras-chaves: Gerência de Recursos de Rádio, Otimização por Enxame de Partículas, Recozimento Simulado.

Abstract

In this monograph the problem of radio resources management is analyzed in systems with interference-limited capacity, such as the WCDMA system. Details are given of an economic model of resource allocation that considers the utility of the provided service, the acceptance probability of the service by the users and the revenue generated for the network operator. This study presents an optimization model with constraints for the problem, while a hybrid metaheuristic technique based on PSO and SA is used to find approximate solutions. The results obtained with simulations developed in software Scilab indicate that the proposed approach is able to provide feasible solutions for the problem from little initial information.

Keywords: Radio Resources Management, Particles Swarm Optimization, Simulated Annealing.

Dedico este trabalho aos meus pais, Fernando Lincoln e Carmen,
pelos ensinamentos mais valiosos.

Agradecimentos

À minha irmã, Fernanda, e aos amigos extra-universidade, que pelo convívio agradável contribuíram indiretamente para a realização desta monografia,

Aos companheiros do curso de graduação em Engenharia de Teleinformática, pela amizade e pela convivência em ambiente universitário,

Aos colegas do SMTRG (*Samsung Movement Tracking and Research Group*), por reforçarem a importância do trabalho em equipe,

Ao Professor Guilherme de Alencar Barreto, pela confiança, incentivo e dedicação durante toda a orientação acadêmica,

Ao Professor Francisco Rodrigo Porto Cavalcanti, pelos ensinamentos e apoio oferecidos,

Aos demais professores do Departamento de Engenharia de Teleinformática, pelos conhecimentos transmitidos durante a minha graduação como Engenheiro,

À Universidade Federal do Ceará, pela formação de nível superior.

A dúvida é o princípio da sabedoria.

Aristóteles

Sumário

Lista de Figuras	viii
Lista de Tabelas	ix
Lista de Símbolos	x
Lista de Siglas	xii
1 Introdução	1
1.1 Motivação	1
1.2 Revisão Bibliográfica	2
1.2.1 Pesquisas em gerência de recursos de rádio	2
1.2.2 Pesquisas em Algoritmos Metaheurísticos	3
1.3 Objetivos	4
1.3.1 Objetivo Geral	4
1.3.2 Objetivos Específicos	4
1.4 Organização da Monografia	4
2 Gerência de Recursos de Rádio	6
2.1 Modelagem do problema	6
2.1.1 Avaliação da qualidade	6
2.1.2 Preço e geração de receita	9
2.1.3 Capacidade em sistemas WCDMA	11
2.1.4 Restrições de alocação de recursos	12
2.1.5 Modelo de perda de percurso	13
2.2 Modelagem da solução	14
2.2.1 Derivada da função utilidade	14
2.2.2 Estratégia baseada em metaheurísticas	15
2.3 Conclusões	17
3 Otimização Metaheurística	18
3.1 O Problema de Otimização	18
3.2 Otimização estocástica	19

3.3	Métodos metaheurísticos	19
3.4	Otimização por Enxame de Partículas	20
3.4.1	PSO original	20
3.4.2	PSO padrão 2007	22
3.5	Otimização com restrições	24
3.6	Avaliação de soluções com restrições	25
3.7	Algoritmos metaheurísticos híbridos	26
3.7.1	Recozimento Simulado	26
3.7.2	Algoritmo PSO Híbrido (HPSO)	27
3.7.3	HPSO como método de solução de problemas de RRM	29
3.8	Conclusões	31
4	Análise dos Resultados	34
4.1	Parâmetros do modelo de alocação de recursos	34
4.2	Parâmetros do processo de otimização	35
4.2.1	Parâmetros da etapa PSO	35
4.2.2	Parâmetros da etapa de SA	37
4.3	Ambiente de testes	37
4.4	Resultados obtidos	37
4.4.1	Variação com número de usuários	38
4.4.2	Variação com a SINR alvo	42
4.4.3	Análise detalhada de alocação de recursos	44
4.5	Conclusões	47
5	Conclusões	52
5.1	Perspectivas para trabalhos futuros	53
Referências Bibliográficas		59

Listas de Figuras

2.1	Exemplo de função de utilidade com $\alpha = 5$ e $\beta = 0,5$	8
2.2	Comportamento da função de aceitação em relação ao preço para $u = 1$, $C = 0,05$, $\mu = 2$ e $\epsilon = 4$	9
2.3	Comportamento da função de aceitação em relação à utilidade para $p = 1$, $C = 0,05$, $\mu = 2$ e $\epsilon = 4$	10
2.4	Exemplo de distribuição espacial de 10 terminais em uma célula de 500m de raio.	13
2.5	Ilustração de um modelo de solução para métodos metaheurísticos. .	16
3.1	Topologia global de enxame para a técnica PSO.	23
3.2	Topologia local de enxame para a técnica PSO.	23
3.3	Fluxograma para algoritmo HPSO com topologia global.	30
3.4	Fluxograma para algoritmo HPSO com topologia local.	31
3.5	Fluxograma para busca local por SA.	32
4.1	Interface gráfica do ambiente de testes.	38
4.2	Evolução típica da função objetivo e das violações para topologia global.	45
4.3	Taxa típica alocada para topologia global.	46
4.4	Potência típica alocada para topologia global.	47
4.5	Utilidade típica para topologia global.	48
4.6	Aceitação típica para topologia global.	49
4.7	Evolução típica da função objetivo e das violações para topologia local.	49
4.8	Taxa típica alocada para topologia local.	50
4.9	Potência típica alocada para topologia local.	50
4.10	Utilidade típica para topologia local.	51
4.11	Aceitação típica para topologia local.	51

Listas de Tabelas

4.1	Parâmetros do modelo de alocação de recursos.	35
4.2	Parâmetros da etapa de PSO.	36
4.3	Parâmetros da etapa de SA.	37
4.4	Resultados obtidos para 8 usuários e tarifação constante.	39
4.5	Resultados obtidos para 8 usuários e tarifação linear.	39
4.6	Resultados obtidos para 10 usuários e tarifação constante.	39
4.7	Resultados obtidos para 10 usuários e tarifação linear.	40
4.8	Resultados obtidos para 12 usuários e tarifação constante.	40
4.9	Resultados obtidos para 12 usuários e tarifação linear.	40
4.10	Resultados obtidos para 14 usuários e tarifação constante.	41
4.11	Resultados obtidos para 14 usuários e tarifação linear.	41
4.12	Resultados obtidos para 10 usuários e SINR 5dB.	43
4.13	Resultados obtidos para 10 usuários e SINR 6dB.	43
4.14	Resultados obtidos para 10 usuários e SINR 7dB.	44
4.15	Parâmetros do cenário para testes detalhados de alocação de recursos.	45
4.16	Resultados obtidos para 10 usuários e SINR 7dB.	45

Lista de Símbolos

r	<i>Taxa de dados alocada</i>
$u(r)$	<i>Função utilidade</i>
α, β	<i>Parâmetros da função utilidade</i>
p	<i>Preço cobrado pelo serviço</i>
$A(u, p)$	<i>Função aceitação</i>
C, μ e ϵ	<i>Parâmetros da função aceitação</i>
N	<i>Número de usuários</i>
R	<i>Receita total gerada</i>
k	<i>Constante de tarifação</i>
$\frac{E_b}{N_0} i$	<i>SINR do i-ésimo terminal</i>
$\frac{E_b}{N_0}$	<i>SINR alvo do sistema</i>
W	<i>Banda de espalhamento do sistema</i>
g	<i>Ganho de potência</i>
pt	<i>Potência alocada</i>
pt_n	<i>Potência do ruído AWGN</i>
I_i^{int}	<i>Interferência interna para o i-ésimo terminal</i>
I_i^{ext}	<i>Interferência externa para o i-ésimo terminal</i>
θ_{ij}	<i>Coeficiente de correlação cruzada entre os terminais i e j</i>
r_{max}	<i>Máxima taxa de dados alocável para um único terminal</i>
pt_{ERB}	<i>Potência total disponível na ERB</i>
d_i	<i>Distância do i-ésimo terminal à ERB</i>
P_{Li}	<i>Perda de percurso associada ao i-ésimo terminal</i>
P_{L0}	<i>Perda de percurso de referência</i>
G_{ant}	<i>Soma dos ganhos das antenas transmissora e receptora</i>
n_{loss}	<i>Coeficiente de perda de percurso</i>
R_{cell}	<i>Raio da célula</i>
X_σ	<i>Sombreamento de desvio padrão σ</i>
$f(\mathbf{x})$	<i>Função-objetivo</i>
\mathbf{x}_i	<i>Vetor de posição da i-ésima partícula</i>
\mathbf{v}_i	<i>Vetor de velocidade da i-ésima partícula</i>
\mathbf{P}_i	<i>Vetor de melhor posição histórica da i-ésima partícula</i>
\mathbf{P}_l	<i>Vetor de melhor posição histórica de uma vizinhança de partículas</i>
\mathbf{P}_g	<i>Vetor de melhor posição histórica global</i>

\mathbf{X}_{min}	<i>Vetor dos menores valores possíveis para as variáveis de uma solução</i>
\mathbf{X}_{max}	<i>Vetor dos os maiores valores possíveis para as variáveis de uma solução</i>
c_1 e c_2	<i>Coeficientes aceleradores</i>
χ	<i>Fator de constrição</i>
$g(\mathbf{x})$	<i>Inequação de restrição</i>
$viol(\mathbf{x})$	<i>Função nível de violações</i>
η	<i>Passo de controle do Recozimento Simulado</i>
t	<i>Parâmetro de temperatura do Recozimento Simulado</i>
λ	<i>Taxa de recozimento</i>

Lista de Siglas

ACO	<i>Ant Colony Optimization</i> (Otimização por Colônia de Formigas)
AG	Algoritmos Genéticos
ERB	Estação Rádio Base
HPSO	<i>Hybrid Particles Swarm Optimization</i> (Otimização Híbrida por Enxame de Partículas)
PSO	<i>Particles Swarm Optimization</i> (Otimização por Enxame de Partículas)
QoS	<i>Quality of Service</i> (Qualidade de Serviço)
RRM	<i>Radio Resource Management</i> (Gerência de Recursos de Rádio)
SA	<i>Simulated Annealing</i> (Recozimento Simulado)
SINR	<i>Signal to Interference plus Noise Ratio</i> (Razão entre Sinal e Interferência Mais Ruído)
WCDMA	<i>Wideband Code Division Multiple Access</i>

Introdução

O setor de telefonia móvel tem experimentado um vasto crescimento nos últimos anos. Em alguns países, como Alemanha, Espanha e Reino Unido, já é observado um número maior de aparelhos celulares que de habitantes. A velocidade dessa expansão tem sido tão intensa que em 2002 menos de 15% da população do mundo possuía celulares, enquanto ao final de 2008 esse número chegou a 60% (ITU, 2008).

Segundo a Teleco, empresa de consultoria do setor de telecomunicações, o Brasil apresenta cerca de 160 milhões de aparelhos e o acesso a celulares de 2008 para 2009 cresceu em quase 20%, caracterizando-se como um dos serviços de comunicação que mais cresce no país. Entretanto, o crescimento da receita gerada nesse segmento no mesmo período foi de apenas 5% (TELECO, 2009). Essa tendência é um indicativo de que as operadoras de comunicações móveis necessitam diversificar os serviços oferecidos para que a base instalada de usuários gere maior lucro.

1.1 Motivação

A gestão de um serviço no setor de telecomunicações tem como objetivo buscar a melhor satisfação do cliente e da empresa que presta o serviço. Para o cliente, deseja-se disponibilizar um atendimento compatível com a sua expectativa, seja em relação à qualidade ou ao preço cobrado pelo mesmo. Para a empresa, a satisfação é alcançada quando mais clientes são admitidos e a receita é elevada.

As necessidades citadas apresentam conceitos subjetivos, como “qualidade” e “receita elevada”, que precisam ser quantificados. Além disso, a operação do serviço

afeta diretamente o comportamento dessas características. Um modelo econômico operacional para esse problema torna-se necessário, assim como uma abordagem para sua solução. Estes assuntos serão discutidos neste trabalho.

1.2 Revisão Bibliográfica

Esta seção tem como objetivo revisar os trabalhos correlatos às áreas dos estudos realizados nesta monografia.

1.2.1 Pesquisas em gerência de recursos de rádio

A gerência de recursos de rádio (*Radio Resource Management* (RRM), em inglês) é a principal responsabilidade das operadoras de redes de comunicações móveis, possuindo grande impacto na qualidade do serviço oferecido pela empresa. Por esse motivo, o assunto tem sido amplamente estudado nos últimos anos.

Há várias abordagens para problemas relacionados a RRM. Alguns trabalhos, como em Narayan *et al.* (2000), Elayoubi e Chahed (2005) e Kelif, Altman e Koukoutsidis (2007), analisam ferramentas de controle de admissão, que selecionam previamente os terminais que serão atendidos e buscam garantir qualidade de serviço (*Quality of Service* (QoS), em inglês) para os usuários aceitos. Essa estratégia se caracteriza por analisar o problema do ponto de vista do usuário, não analisando diretamente os objetivos da provedora do serviço.

Outros autores discutem problemas de RRM utilizando conceitos de Teoria dos Jogos, como em Famolari *et al.* (1998), Yaiche, Mazumdar e Rosenberg (2000) e Xiao, Shroff e Chong (2003). Nessa abordagem, a medida de QoS é vista como a função de utilidade que cada usuário tenta maximizar, formando um jogo não-cooperativo com a presença de vários usuários no papel dos jogadores. Entretanto, nesse jogo que modela o problema, a operadora é vista somente como um árbitro ou um mediador (BADIA *et al.*, 2003).

Alguns pesquisadores adicionam uma análise econômica aos seus estudos do problema de operação de redes de comunicações verificando a sustentabilidade do modelo, a política de cobrança pelo serviço e a capacidade de geração de receita do mesmo. Esse ponto de vista da operadora é abordado em Badia *et al.* (2004), Elayoubi, Chahed e Salahaldin (2005) e Neto e Cavalcanti (2007). A presente monografia utilizará tais elementos econômicos para modelar o problema de alocação de recursos em sistemas de comunicações móveis.

1.2.2 Pesquisas em Algoritmos Metaheurísticos

Como será explicado com mais detalhes posteriormente neste trabalho, métodos metaheurísticos são algoritmos que utilizam um conjunto de instruções sistemáticas para obter soluções para problemas matemáticos. Nesta seção um breve histórico do assunto é revisado.

Desde a década de 1950, pesquisadores têm estudado técnicas estocásticas para aproximação de soluções em problemas de otimização, como o trabalho pioneiro realizado em Robbins e Monroe (1951). Já em Barricelli *et al.* (1954), inicia-se pesquisas relacionadas à evolução artificial. Mas somente em Rechenberg (1964) é concebido o primeiro algoritmo baseado em estratégias evolucionárias, permitindo que em Fogel, Owens e Walsh (1966) fosse proposto o método de programação evolucionária.

Nas décadas de 1970 e 1980 foram introduzidas várias novas técnicas, como os primeiros Algoritmos Genéticos (AG) em Holland (1975), a técnica de Recozimento Simulado (*Simulated Annealing* (SA), em inglês) em Kirkpatrick *et al.* (1983) e o método da Busca Tabu em Glover (1986), onde foi introduzido o termo “metaheurística”.

Nas décadas seguintes diversos pesquisadores continuaram a estudar diferentes métodos metaheurísticos, sendo os mais promissores os realizados em Dorigo (1992), tese de doutorado que propôs um algoritmo de otimização inspirado em colônias de formigas (*Ant Colony Optimization* (ACO), em inglês), e em Kennedy e Eberhart (1995), no qual apresentou-se um método baseado em enxame de partículas (*Particles Swarm Optimization* (PSO), em inglês). Trabalhos recentes continuam a abordar novas técnicas e variações de algoritmos metaheurísticos já existentes, indicando o interesse da comunidade científica em explorar o assunto.

Em Badia *et al.* (2005) é realizado o uso de AG na estimativa de soluções para problemas de RRM. Os bons resultados obtidos nesse trabalho revelam que a utilização de métodos metaheurísticos nesse contexto é relevante. Nesta monografia as ferramentas estudadas são as técnicas de PSO e SA, ambas bastante populares no estudo de problemas de otimização em geral.

1.3 Objetivos

O objetivo geral desta monografia, assim como seus objetivos específicos, são apresentados nesta seção.

1.3.1 Objetivo Geral

O principal objetivo desta monografia é a aplicação de um algoritmo de otimização metaheurística na resolução de problemas de gerência de recursos de rádio em sistemas de comunicações móveis. O estudo será feito em sistemas com capacidade limitada por interferência, tal como o sistema *Wideband Code Division Multiple Access* (WCDMA). A análise do problema de alocação de recursos apresentará uma abordagem econômica.

A principal contribuição desta monografia consiste na utilização de técnicas metaheurísticas em problemas de gerência de recursos de rádio considerando-se a receita gerada para a operadora do serviço de telecomunicação.

1.3.2 Objetivos Específicos

Os objetivos específicos desta monografia estão listados a seguir:

- 1 Modelar o problema de alocação de recursos de rádio com foco na receita gerada para a operadora do serviço de telecomunicação.
- 2 Propor um modelo de solução para problemas de otimização com restrições a partir de técnicas metaheurísticas.
- 3 Implementar um algoritmo metaheurístico híbrido baseado em PSO e SA.
- 4 Realizar testes sistemáticos para avaliar a utilização da técnica metaheurística implementada na resolução do problema de otimização estudado.

1.4 Organização da Monografia

Os estudos deste trabalho estão organizados da seguinte forma. No Capítulo 2 o problema de gestão de recursos de rádio é detalhado e um modelo econômico para o mesmo é apresentado. No Capítulo 3 é descrito o algoritmo metaheurístico utilizado no processo de otimização. No Capítulo 4 são apresentados e discutidos os

resultados obtidos no trabalho. Finalmente, no Capítulo 5 são feitas as conclusões finais e elaboradas perspectivas para trabalhos posteriores.

Capítulo 2

Gerência de Recursos de Rádio

Neste capítulo um modelo econômico de gerência de recursos de rádio é descrito e são estudadas algumas possíveis soluções para problemas de otimização modelados desta forma.

2.1 Modelagem do problema

Um modelo de gerência de recursos deve encontrar os parâmetros do sistema que modificam o funcionamento do mesmo e relacioná-los com métricas que representem a qualidade de uma determinada solução para o problema. Essas etapas serão analisadas nesta seção.

2.1.1 Avaliação da qualidade

Antes do processo de otimização é preciso determinar as funções que vão orientar a escolha de valores para os parâmetros envolvidos. A seguir algumas dessas funções são analisadas.

Utilidade

A utilidade de um serviço corresponde ao nível de satisfação que um indivíduo apresenta ao usufruir daquele serviço. De acordo com esta definição, a utilidade pode ser vista como uma métrica para a qualidade de um serviço fornecido.

Considerando a função utilidade $u(r)$, na qual r é um parâmetro diretamente relacionado à qualidade do serviço em questão, pode-se restringir as possíveis formas

de $u(r)$ pelas seguintes restrições (BADIA *et al.*, 2004):

$$\frac{du(r)}{dr} \geq 0, \quad (2.1)$$

$$\lim_{r \rightarrow \infty} \frac{du(r)}{dr} = 0. \quad (2.2)$$

A Equação (2.1) indica que a função utilidade deve crescer de acordo com o aumento de r , enquanto a Equação (2.2) determina que para valores elevados de r a derivada da função $u(r)$ tende a zero. Funções sigmoides têm sido comumente usadas para representar utilidade por apresentarem estas propriedades (BADIA; ZORZI, 2004).

Na gerência de recursos de rádio, o parâmetro r pode ser visto como um ou mais recursos que devem ser compartilhados entre os usuário da rede. O modelo utilizado não restringe essa escolha, mas para a análise deste capítulo considera-se r como a taxa alocada para a transferência de dados.

Usuários de um sistema de comunicações móveis apresentam comportamentos distintos de necessidade por recursos de infraestrutura da rede, seja por causa de diferentes planos de acesso ou devido aos padrões de uso de serviço oferecidos. Entretanto, a utilidade do i -ésimo usuário pode ser formulada pela seguinte expressão normalizada no intervalo $[0, 1]$ (BADIA *et al.*, 2004):

$$u_i(r_i) \triangleq \frac{(r_i/\beta_i)^{\alpha_i}}{1 + (r_i/\beta_i)^{\alpha_i}}, \quad (2.3)$$

em que r_i é a taxa alocada e α_i e β_i são parâmetros que diferenciam os usuários entre si, sendo $\alpha_i \geq 0$ e $\beta_i > 0$. Tais parâmetros modificam o formato de $u_i(r_i)$ de acordo com a realidade de cada usuário.

Um esboço da curva descrita pela Equação (2.3) pode ser vista na Figura 2.1, para $\alpha = 5$ e $\beta = 0,5$.

Aceitação

Pode-se determinar para cada usuário do sistema uma probabilidade de aceitação do serviço $A(u, p)$ dependente da utilidade proporcionada u e do preço cobrado p .

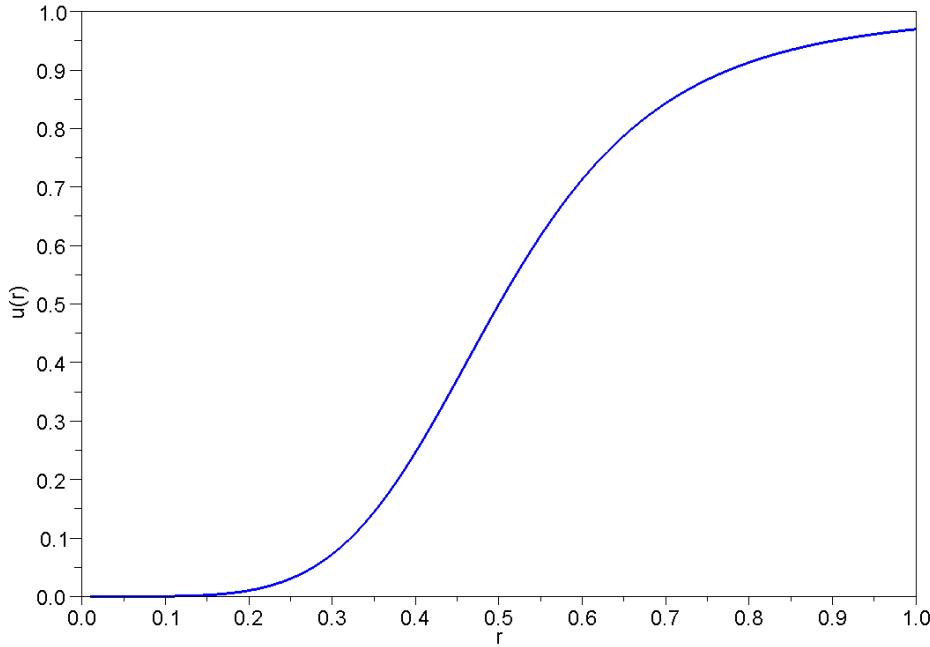


Figura 2.1: Exemplo de função de utilidade com $\alpha = 5$ e $\beta = 0,5$.

Deve-se observar as seguintes propriedades nessa função (BADIA *et al.*, 2004):

$$\frac{\partial A}{\partial u} \geq 0, \quad \frac{\partial A}{\partial p} \leq 0. \quad (2.4)$$

$$\forall p > 0, \quad \lim_{u \rightarrow 0} A(u, p) = 0, \quad \lim_{u \rightarrow \infty} A(u, p) = 1. \quad (2.5)$$

$$\forall u > 0, \quad \lim_{p \rightarrow 0} A(u, p) = 1, \quad \lim_{p \rightarrow \infty} A(u, p) = 0. \quad (2.6)$$

Uma função que possui estas propriedades e é muito utilizada na microeconomia é a relacionada às curvas de demanda de Cobb-Douglas (VARIAN, 1999):

$$A(u, p) \triangleq 1 - e^{-Cu^\mu p^{-\epsilon}}, \quad (2.7)$$

na qual C , μ e ϵ são constantes positivas.

As Figuras 2.2 e 2.3 mostram o comportamento da função de aceitação quando mantém-se a utilidade constante e o preço constante, respectivamente.

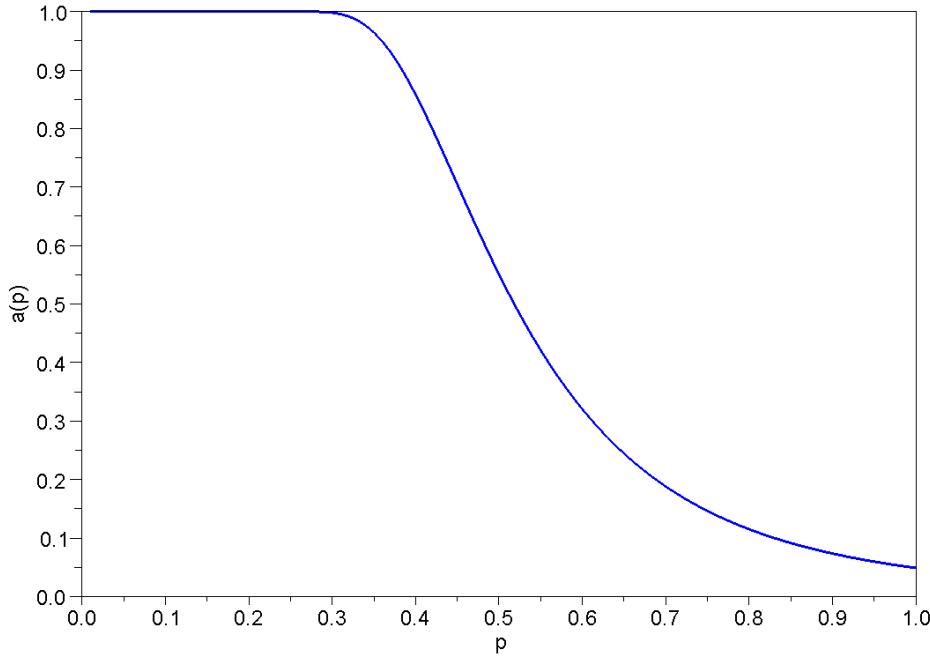


Figura 2.2: Comportamento da função de aceitação em relação ao preço para $u = 1$, $C = 0,05$, $\mu = 2$ e $\epsilon = 4$.

2.1.2 Preço e geração de receita

Tratando o problema de alocação de recursos de rádio como um problema de otimização, deve-se determinar uma métrica como função-objetivo com a qual se deseja trabalhar. A partir das funções definidas nas Equações (2.3) e (2.7), pode-se formular algumas possíveis escolhas (BADIA; ZORZI, 2004):

$$R = \sum_{i=1}^N p_i A(u_i, p_i), \quad (2.8)$$

$$S = \sum_{i=1}^N A(u_i, p_i), \quad (2.9)$$

$$T = \sum_{i=1}^N r_i A(u_i, p_i), \quad (2.10)$$

$$U = \sum_{i=1}^N u_i A(u_i, p_i), \quad (2.11)$$

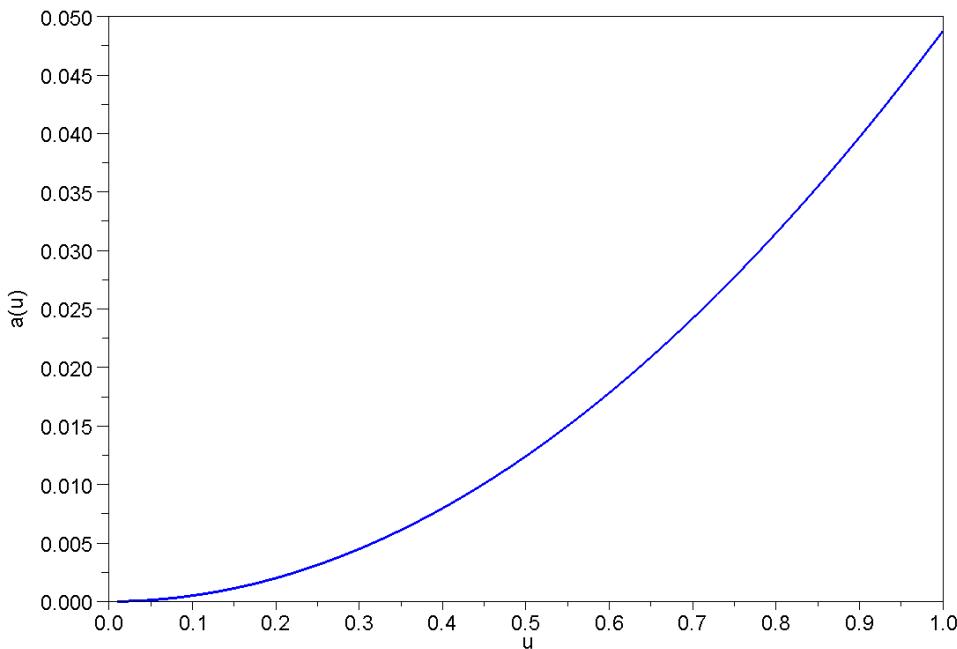


Figura 2.3: Comportamento da função de aceitação em relação à utilidade para $p = 1$, $C = 0,05$, $\mu = 2$ e $\epsilon = 4$.

sendo N o número total de usuários, R a receita total gerada, S o número de usuários admitidos, T a quantidade total de recursos alocados e U a utilidade total. Nesta monografia é utilizada a relação expressa na Equação (2.8) como meta de otimização, mas a modelagem do problema é idêntica para outras abordagens. Como será visto no Capítulo 3, a ferramenta utilizada no processo de otimização também não é restrita a essa escolha.

A Equação (2.8) mostra uma forte dependência com a aceitação definida na Equação (2.7). Já a função aceitação é crescente com a função utilidade, que por sua vez aumenta de acordo com o valor de r_i , como visto na Equação (2.3). Essas relações permitem a taxa de dados alocada para cada usuário se tornar o principal parâmetro regulável do problema.

Analizando as Equações (2.7) e (2.8) pode-se perceber ainda que a função de aceitação é decrescente com o valor do preço, enquanto a receita total cresce com o produto do preço pela aceitação. A partir dessas informações conclui-se que não é possível aumentar indiscriminadamente o valor cobrado pelo serviço, sugerindo que haja um ponto de equilíbrio que maximize a receita gerada. Dessa forma, o preço

será outro parâmetro regulado na etapa de otimização.

A cobrança pela utilização de um recurso pode ser feita de diversas maneiras diferentes. Duas das mais simples formas são o preço constante, em que $p_i = p$, e o preço linear, onde o valor cobrado cresce linearmente com a quantidade de recursos usada, $p_i = kr_i$, sendo k uma constante positiva. Nesse trabalho utiliza-se essas duas abordagens, mas a política de cobrança determinada pelo serviço não afeta a modelagem do problema e sua resolução.

2.1.3 Capacidade em sistemas WCDMA

Em sistemas limitados por interferência, como o sistema WCDMA, a capacidade é dita *soft*, ou seja, é determinada pela situação atual do sistema. Nesse modelo de múltiplo acesso, novos usuários somente são bloqueados caso a interferência promovida pelo mesmo comprometa a qualidade de serviço dos demais.

Considerando-se o enlace direto (*downlink*), existe uma equação que relaciona a taxa r_i alocada para o i -ésimo usuário, a potência p_i da antena necessária para promover tal taxa, a qualidade do sinal e a interferência do sistema (NETO; CAVALCANTI, 2007):

$$\frac{E_b}{N_{0i}} = \frac{W}{r_i} \frac{g_i p t_i}{I_i^{int} + I_i^{ext} + p t_n}, \quad (2.12)$$

$$\text{em que } I_i^{int} = \sum_{j \neq i} \theta_{ij} g_i p t_j. \quad (2.13)$$

Na Equação (2.12) $\frac{E_b}{N_{0i}}$ é a Razão entre Sinal e Interferência Mais Ruído (*Signal to Interference plus Noise Ratio* (SINR), em inglês) do usuário i , W é a banda de espalhamento do sistema, g_i , r_i e $p t_i$ são respectivamente o ganho de potência, a taxa de dados e a potência alocadas para o usuário i . I_i^{int} é o total de interferência interna à célula, sendo θ_{ij} os coeficientes de correlação cruzada entre os códigos de espalhamento dos usuários i e j . O termo I_i^{ext} corresponde à interferência externa à célula e $p t_n$ é a potência do ruído AWGN.

Em Pedersen e Mogensen (2002) é proposta uma aproximação para o coeficiente de ortogonalidade experimentado por cada terminal em função da sua distância à Estação Rádio Base (ERB). O coeficiente de correlação cruzada θ_{ij} pode ser visto como o complementar do coeficiente de ortogonalidade. Nesse caso, para dois códigos ortogonais, tem-se o coeficiente de ortogonalidade igual à unidade e θ_{ij} nulo.

Considerando $\theta_{ij} = \theta_i$ para todo j , tem-se:

$$\theta_i \approx 1 - \frac{1}{1 + \kappa d_i}, \quad (2.14)$$

em que d_i é a distância em metros do i -ésimo terminal à ERB e $\kappa = 0,0029$, como proposto em Pedersen e Mogensen (2002).

Utilizando a Equação (2.14) na Equação (2.13), tem-se a seguinte interferência interna total para o usuário i :

$$I_i^{int} = \left(1 - \frac{1}{1 + \kappa d_i}\right) g_i \sum_{j \neq i} pt_j. \quad (2.15)$$

Pela Equação (2.12) pode-se perceber que, fixando $\frac{E_b}{N_0}_i$, a mudança de r_i implica na mudança de pt_i , que por sua vez resulta na alteração do valor de I_i^{int} para outros usuários. Dessa forma, pt_i torna-se também um parâmetro regulável durante a otimização.

2.1.4 Restrições de alocação de recursos

Pelas equações apresentadas neste capítulo, percebe-se que há uma forte relação entre as variáveis que definem um problema de alocação de recursos. A existência das componentes I_i^{int} e I_i^{ext} na Equação (2.12) indica ainda que a alteração dos parâmetros de um usuário influencia diretamente na qualidade do sinal dos demais usuários. Além disso, os parâmetros a serem regulados não podem assumir qualquer valor e devem respeitar os limites físicos da antena transmissora e da célula em questão.

Dessa forma, deve-se criar uma série de restrições que precisam ser atendidas a todo momento no processo de otimização para cada usuário i , tais como

$$r_i \leq r_{max}, \quad (2.16)$$

$$\sum_{i=1}^N pt_i \leq pt_{ERB}, \quad (2.17)$$

$$\frac{E_b}{N_0}_i \geq \frac{E_b}{N_0}, \quad (2.18)$$

em que r_{max} é a máxima taxa que pode ser alocada para um único usuário, pt_{ERB} é a potência total disponível para transmissão na ERB e $\frac{E_b}{N_0}$ é o menor valor desejável

para a SINR.

2.1.5 Modelo de perda de percurso

Visando tornar o modelo do problema mais próximo da situação real de uma célula contendo usuários de um sistema de comunicação móvel, antes do processo de otimização, terminais são distribuídos aleatoriamente em uma área circular. Um exemplo dessa organização pode ser visualizado na Figura 2.4.

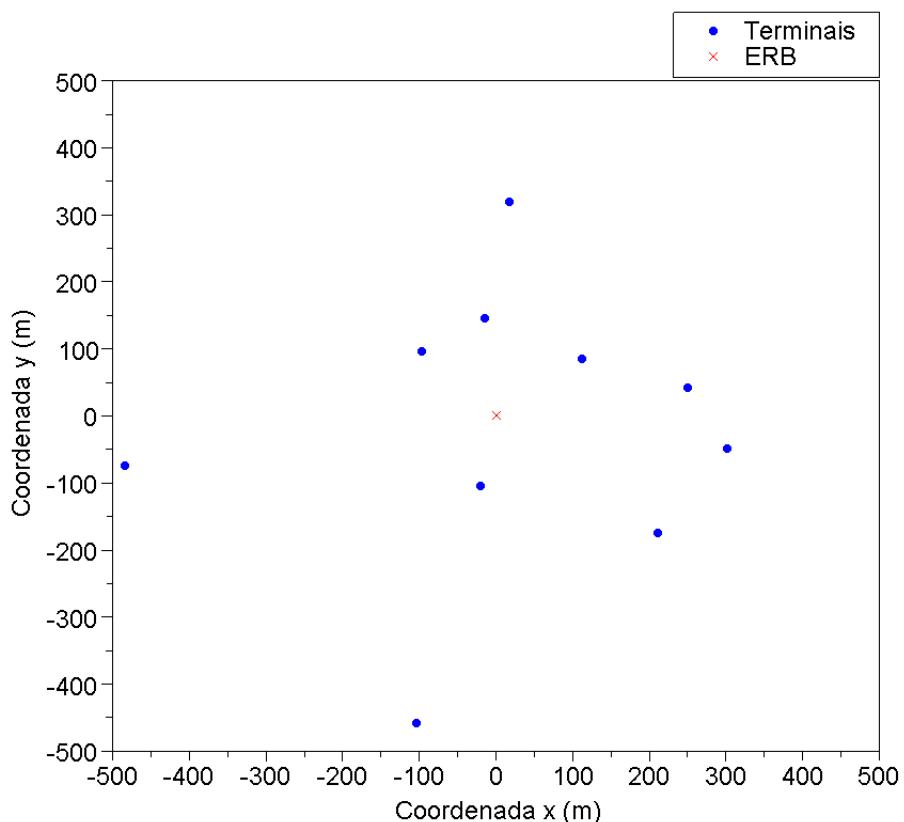


Figura 2.4: Exemplo de distribuição espacial de 10 terminais em uma célula de 500m de raio.

Posicionando a ERB no centro dessa área, calcula-se a distância de cada usuário à antena transmissora e a respectiva perda de percurso envolvida. Por motivos de simplificação, o modelo de perda de percurso linear é utilizado. Nesse modelo, a partir de um ponto de referência obtém-se o valor de perda de percurso de qualquer outro ponto.

Considerando $rand()$ uma função que retorna um número pseudo-aleatório uniformemente distribuído entre 0 e 1, G_{ant} a soma dos ganhos da antena

transmissora e receptora, R_{cell} o raio da célula, n_{loss} o coeficiente de perda de percurso, d_0 a distância da ERB ao ponto de referência, P_{L0} a perda de percurso nesse ponto em dB e X_σ uma variável aleatória log-normal representando o sombreamento com desvio padrão σ , tem-se para o i -ésimo usuário:

$$d_i = \text{rand}() \times R, \quad (2.19)$$

$$P_{Li} = P_{L0} - G_{ant} + 10n_{loss} \log\left(\frac{d_i}{R_{cell}}\right) - X_\sigma, \quad (2.20)$$

em que d_i é a distância do terminal à ERB e P_{Li} é a perda de percurso associada em dB. Essa perda relaciona-se com o ganho g_i da Equação (2.12) pela expressão abaixo:

$$g_i = 10^{\frac{-P_{Li}}{10}}. \quad (2.21)$$

2.2 Modelagem da solução

A resolução de um problema de otimização a partir de seu modelo consiste em determinar um conjunto de parâmetros que satisfaça as restrições existentes e forneçam valores aceitáveis para a função-objetivo escolhida. Esta seção descreve a abordagem tradicional e a baseada em técnicas metaheurísticas, sendo esta última a utilizada neste trabalho.

2.2.1 Derivada da função utilidade

Uma possível estratégia para a solução do problema de otimização da receita total envolve a derivada da função utilidade. Essa abordagem baseia-se na lei da utilidade marginal decrescente (CASE; FAIR, 2003), que determina que a satisfação ao consumir um produto ou serviço é reduzida com o aumento desse consumo.

No caso do problema de alocação de recursos, percebe-se que a partir de uma certa quantidade de recursos r^* alocada para um usuário, a utilidade será pouco alterada com o aumento da taxa alocada. Esse fenômeno envolve a redução do valor da derivada da função utilidade para valores próximos de zero.

Utilizando essa informação durante o processo de gerenciamento de recursos e sendo $u'(r)$ a derivada da função utilidade, tem-se a seguinte regra de alocação (NETO; CAVALCANTI, 2007):

$$r_i^* = \max\{r : u'(r) = \vartheta\} \cap [0, r^{max}], \quad (2.22)$$

em que ϑ é um limiar positivo próximo de zero que deve ser escolhido pela operadora. Quanto maior o valor desse limiar, menor a taxa alocada para cada usuário, mas uma maior quantidade de usuários pode ser aceita. Quanto menor o valor, mais taxa é alocada, porém menos usuários são servidos.

Dessa forma, a estratégia convencional de alocação de recursos determina a partir da Equação (2.22) a taxa a ser alocada para um novo usuário e então verifica se a potência necessária relacionada àquele recurso é factível, utilizando a Equação (2.12) com um valor alvo para $\frac{E_b}{N_0 i}$. Caso a potência necessária não ultrapasse o total de potência da ERB, o recurso será alocado. Caso contrário, a quantidade de recurso é diminuída em um certo valor, por exemplo, em 20%, sendo feito um novo cálculo da potência necessária. O processo é repetido até que uma potência possível seja alcançada. Nessa abordagem, usuários com recursos já alocados não apresentarão mudanças de alocação quando ocorrer a adição de novos usuários.

Outra estratégia consiste em fixar a potência de transmissão reservada para cada usuário e igualar $\frac{E_b}{N_0 i}$ a um valor desejado, calculando em seguida a taxa possível de ser alocada para cada terminal. Apesar dessa abordagem garantir a obtenção de uma SINR mínima, ela não optimiza a alocação de recursos.

2.2.2 Estratégia baseada em metaheurísticas

Será visto no Capítulo 3 que métodos metaheurísticos são capazes de aproximar soluções de problemas de otimização em geral a partir de um conjunto de procedimentos genéricos que necessitam de pouca informação acerca da situação de interesse. Por causa dessa última característica, pode-se reduzir o modelo apresentado quando utiliza-se a abordagem heurística.

Como visto nas seções anteriores, os parâmetros do problema de gerenciamento de recursos que podem ser regulados são a taxa r_i alocada por usuário, a potência de transmissão pt_i reservada para cada usuário, o preço p (tarifação constante) ou k (tarifação linear) cobrado pelo serviço e o limiar de alocação ϑ . Entretanto, ϑ não é uma variável do problema em si, mas sim variável de uma possível regra de alocação. Métodos heurísticos não utilizam esse tipo de regra na sua execução, já que realizam uma busca no espaço de soluções possíveis. Dessa forma, é possível eliminar ϑ da lista de parâmetros do problema.

A Equação (2.12) revela uma relação entre as grandezas r_i , pt_i e $\frac{E_b}{N_0 i}$. Caso $\frac{E_b}{N_0 i}$ seja mantido constante igual a $\frac{E_b}{N_0}$ para todos os terminais, obtém-se a seguinte

relação única entre r_i e pt_i :

$$r_i = \frac{W}{\frac{E_b}{N_0} I_i^{int} + I_i^{ext} + pt_n} \frac{g_i pt_i}{.} \quad (2.23)$$

Em Badia, Telesca e Zorzi (2006) demonstra-se que a decisão de substituir a inequação da restrição (2.18) por uma igualdade é aceitável quando considera-se um sistema limitado por interferência. É feito ainda a consideração de que o valor especificado para $\frac{E_b}{N_0}$ é suficiente para garantir uma qualidade satisfatória para o serviço. Esse procedimento permite a redução da dimensionalidade do modelo ao eliminar a necessidade de analisar a taxa e a potência alocadas separadamente, simplificando a resolução do problema.

Como r_i deixa de ser variável independente do problema, as restrições do processo de alocação podem ser reescritas da seguinte forma:

$$\frac{W}{\frac{E_b}{N_0} I_i^{int} + I_i^{ext} + pt_n} \leq r_{max}, \quad (2.24)$$

$$\sum_{i=1}^N pt_i \leq pt_{ERB}, \quad (2.25)$$

$$\frac{E_b}{N_0} = \frac{E_b}{N_0}. \quad (2.26)$$

Na maioria dos métodos metaheurísticos, é preciso formatar uma possível solução para que ela seja melhorada pelo algoritmo. Considerando um total de N usuários no sistema, pode-se organizar as componentes de uma dada solução como na Figura 2.5.

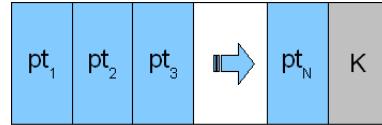


Figura 2.5: Ilustração de um modelo de solução para métodos metaheurísticos.

A partir desse formato, cada solução será composta por $M = N + 1$ variáveis, ou seja, por um vetor M -dimensional.

Já foi comentado que o modelo descrito tem com objetivo maximizar a receita gerada total. Entretanto, é costumeiro tratar problemas de otimização como problemas de minimização. Portanto, a função-objetivo $f(\mathbf{x})$ passa a ser descrita

por

$$f(\mathbf{x}) = \frac{1}{\sum_{i=1}^N p_i A(u_i, p_i)}. \quad (2.27)$$

2.3 Conclusões

Neste capítulo foi detalhado um modelo de gerência de recursos de rádio baseado em conceitos econômicos. O foco da análise realizada foi mantido na operadora do serviço de telecomunicações e os compromissos que esta possui em relação à alocação de recursos aos usuários.

Embora o modo de acesso adotado tenha sido o sistema WCDMA, a análise permanece válida para qualquer sistema que seja similarmente limitado por interferência. O mesmo se aplica às escolhas das expressões utilizadas para descrever a utilidade e a aceitação, assim como a política de cobrança pelo serviço.

No próximo capítulo será estudada a resolução de problemas de otimização a partir da aplicação de métodos metaheurísticos com base nos conceitos apresentados.

Capítulo 3

Otimização Metaheurística

Métodos de otimização são aplicados em todas as áreas da engenharia. A resolução de muitos problemas reais envolve a escolha de um conjunto de parâmetros que permita a obtenção de uma resposta desejada a partir de um sistema em estudo. Entretanto, pelo nível de complexidade muitas vezes observado, soluções analíticas não são possíveis de serem obtidas.

Neste capítulo será descrito uma técnica de otimização metaheurística capaz de obter soluções para esse tipo de problema.

3.1 O Problema de Otimização

Seja $\Theta \subseteq \mathbb{R}^d$ um domínio de valores possíveis para o vetor \mathbf{x} d -dimensional. O objetivo de um problema de otimização consiste em encontrar valores para $\mathbf{x} \in \Theta$ que minimizem uma determinada função escalar $f(\mathbf{x})$, chamada de função de perdas, função de avaliação ou função-objetivo. Formalmente, problemas de otimização podem ser descritos pela expressão abaixo (GENTLE; HÄRDLE; MORI, 2004):

$$\Theta^* \equiv \arg \min_{\mathbf{x} \in \Theta} f(\mathbf{x}) = \{\mathbf{x}^* \in \Theta : f(\mathbf{x}^*) \leq f(\mathbf{x}), \forall \mathbf{x} \in \Theta\}, \quad (3.1)$$

em que Θ^* é o conjunto de soluções que minimiza a função $f(\mathbf{x})$ para $\mathbf{x} = \mathbf{x}^*$.

Uma das principais dificuldades encontradas durante a resolução de um problema de otimização é o comportamento da função-objetivo, pois esta pode ser não-linear, não-diferenciável e depender de parâmetros de dimensão elevada. Nessa classe de problemas a aplicação de métodos de otimização clássicos determinísticos pode ser

inadequada. Técnicas estocásticas, por outro lado, não possuem essa restrição.

3.2 Otimização estocástica

Uma estratégia para a solução de problemas de otimização consiste em construir um espaço de soluções a partir das variáveis em estudo. Considerando que esse espaço apresente soluções vizinhas similares, ou seja, boas soluções estão agrupadas e situam-se longe de soluções ruins, pode-se reduzir consideravelmente o custo da otimização através de métodos de busca. Tais métodos podem ser de natureza determinística ou estocástica (LØVBJERG, 2002).

Algoritmos de otimização estocástica têm sido muito utilizados nos últimos anos na resolução de problemas que apresentam muitas variáveis, funções-objetivo não-diferenciáveis e, possivelmente, um conjunto de restrições fortes. Problemas com essas características são comuns em situações reais e freqüentemente não podem ser resolvidos de maneira satisfatória (qualidade da solução e tempo de processamento razoáveis) por métodos determinísticos. É importante perceber que nem sempre a solução ótima exata é obtida em técnicas estocásticas, mas sim uma solução sub-ótima, normalmente próxima da ideal e que possa ser obtida em tempo hábil.

Métodos de busca estocástica possuem vantagens sobre métodos determinísticos exatos. Em primeiro lugar, a abordagem estocástica permite resolver problemas complexos a partir de pouca informação *a priori* sobre o problema. Além disso, é possível a obtenção de resultados parciais a cada passo de execução do algoritmo, tornando possível a realização de uma troca entre a qualidade da solução e o tempo de processamento (LØVBJERG, 2002).

De maneira geral, algoritmos de otimização estocástica são métodos de otimização que apresentam comportamento probabilístico na geração de soluções para o problema ou no processo de busca em si (SPALL, 2003). No caso de interesse, as variáveis do problema e a função-objetivo que se deseja otimizar são determinísticas, enquanto as regras que regem a busca no espaço de soluções são probabilísticas.

3.3 Métodos metaheurísticos

A palavra “*heurística*” é originada da palavra grega “*heuriskein*”, que significa “*a arte de descobrir novas estratégias para resolver problemas*”. Já o prefixo “*meta*”,

também de origem grega, significa “*em um nível superior*” (TALBI, 2009). Em Glover (1986), a expressão “*técnicas de busca metaheurísticas*” é introduzida e definida como sendo “*metodologias gerais em um nível mais alto de abstração capazes de guiar a modelagem de solução de problemas de otimização*”.

Comumente, metaheurísticas são desenvolvidas inspiradas na observação da natureza. Fenômenos naturais mostram que é possível resolver problemas difíceis a partir de interações aleatórias locais. Como exemplo, pode-se citar o trabalho conjunto de uma colônia de formigas em busca da melhor rota até fontes de alimento. AG, ACO, PSO e SA, técnicas já citadas anteriormente nesta monografia, são exemplos de técnicas metaheurísticas populares inspiradas na observação da natureza.

Algoritmos como PSO, AG e ACO são baseados em populações, ou seja, a cada iteração um conjunto de possíveis soluções são testadas e possivelmente aprimoradas. Enquanto isso, técnicas orientadas a trajetória, como o método SA, determinam uma única solução a cada iteração (ANGHINOLFI; PAOLUCCI, 2008).

3.4 Otimização por Enxame de Partículas

Nesta seção analisa-se a técnica PSO, uma das mais populares metaheurísticas para otimização de funções. Diversos conceitos e variações desse algoritmo serão descritos, enquanto estudos mais detalhados podem ser conferidos nas referências citadas.

3.4.1 PSO original

Proposto em 1995 por Kennedy e Eberhart, a técnica PSO é inspirada no comportamento social e na auto-organização de grupos de pássaros migratórios e cardumes de peixes (KENNEDY; EBERHART, 1995). O comportamento social, demonstrado a partir da troca de informação entre os elementos da população, gera a exploração por melhores soluções, enquanto o aprendizado individual corresponde à componente de exploração¹. Esse método tem se mostrado eficiente e de simples execução para a resolução de vários problemas reais de otimização.

A versão original da técnica PSO envolve a consideração de um enxame

¹Exploração é um neologismo criado a partir da palavra “*exploitation*”, em inglês. Nesta monografia, o termo exploração refere-se ao processo de exploração do espaço de busca considerando as informações das regiões anteriormente visitadas

de partículas distribuídas em um espaço de soluções, sendo a posição de uma determinada partícula correspondente a uma possível solução. Cada partícula possui ainda uma velocidade associada que indica a sua tendência de movimento pelo espaço. As informações obtidas por cada partícula são utilizadas na busca por boas soluções a partir de uma organização em que todas as partículas têm conhecimento da melhor posição alcançada pelas demais. Essa forma de organização caracteriza uma topologia global de enxame.

Sejam $\mathbf{x}_i \in \mathbb{R}^d$ e $\mathbf{v}_i \in \mathbb{R}^d$, respectivamente, os vetores de posição e de velocidade do i -ésimo elemento de um enxame de partículas d -dimensionais, em que d é o número de variáveis das soluções. Sejam ainda $\mathbf{p}_i \in \mathbb{R}^d$ e $\mathbf{p}_g \in \mathbb{R}^d$, respectivamente, os vetores de melhor posição histórica individual da partícula i e melhor posição histórica global. Abaixo tem-se a definição desses vetores:

$$\begin{aligned}\mathbf{x}_i &= [x_{i,1}, x_{i,2}, \dots, x_{i,d}]^T, \\ \mathbf{v}_i &= [v_{i,1}, v_{i,2}, \dots, v_{i,d}]^T, \\ \mathbf{p}_i &= [p_{i,1}, p_{i,2}, \dots, p_{i,d}]^T, \\ \mathbf{p}_g &= [p_{g,1}, p_{g,2}, \dots, p_{g,d}]^T.\end{aligned}$$

Dessa maneira, a técnica PSO original pode ser implementada pelo seguinte algoritmo.

Passo 1 Iniciar as variáveis do enxame de partículas com os seguintes valores:

$$\begin{aligned}\mathbf{x}_i(0) &= \mathbf{X}_{min} + (\mathbf{X}_{max} - \mathbf{X}_{min})\mathbf{U}, \\ \mathbf{v}_i(0) &= (\mathbf{X}_{max} - \mathbf{X}_{min})\mathbf{U} - \mathbf{x}_i(0), \\ \mathbf{p}_i(0) &= \mathbf{0}, \\ \mathbf{p}_g(0) &= \mathbf{0},\end{aligned}$$

em que \mathbf{U} é um vetor d -dimensional de números aleatórios uniformemente distribuídos entre 0 e 1, $\mathbf{0}$ é o vetor nulo de dimensão d e $\mathbf{X}_{min} \in \mathbb{R}^d$ e $\mathbf{X}_{max} \in \mathbb{R}^d$ são respectivamente os menores e maiores valores das variáveis que compõem uma possível solução.

Passo 2 Calcular o valor da função-objetivo $f(\mathbf{x})$ para todas as partículas. O vetor \mathbf{p}_i de cada partícula recebe a posição atual, assim como seu valor associado

recebe o valor da função-objetivo daquela partícula. Já \mathbf{p}_g e seu valor objetivo recebem a melhor posição e a melhor função-objetivo entre todas as partículas do enxame.

Passo 3 Atualizar as posições e velocidades das partículas de acordo com as expressões abaixo, considerando k a iteração atual:

$$v_{i,j}(k+1) = v_{i,j}(k) + c_1 r_1(p_{i,j} - x_{i,j}(k)) + c_2 r_2(p_{g,j} - x_{i,j}(k)), \quad (3.2)$$

$$x_{i,j}(k+1) = x_{i,j}(k) + v_{i,j}(k+1), \quad j = 1, 2, \dots, d \quad (3.3)$$

Na Equação (3.2) c_1 e c_2 são constantes positivas chamadas de coeficientes aceleradores, enquanto r_1 e r_2 são variáveis aleatórias independentes uniformemente distribuídas no intervalo $[0, 1]$.

Passo 4 Avaliar os valores das funções-objetivo de todas as partículas.

Passo 5 Para cada partícula, comparar o valor objetivo atual com o valor de \mathbf{p}_i . Caso o atual seja melhor, \mathbf{p}_i recebe a posição atual e o valor da função-objetivo associado.

Passo 6 Encontrar o melhor valor objetivo entre as partículas atuais e comparar com o valor associado a \mathbf{p}_g . Caso haja melhora, \mathbf{p}_g recebe a posição e a função-objetivo da melhor partícula.

Passo 7 Repetir o processo a partir do Passo 3 até que uma condição de parada seja encontrada.

A busca global promovida pela técnica PSO, causada pela troca de informação entre as partículas, é efeito do termo $c_2 r_2(p_{g,j} - x_{i,j}(k))$ da Equação (3.2). Já o termo $c_1 r_1(p_{i,j} - x_{i,j}(k))$ da Equação (3.2) indica a busca local motivada pelo histórico experimentado por cada partícula.

3.4.2 PSO padrão 2007

Em Bratton e Kennedy (2007), um dos criadores do algoritmo PSO original analisa as diversas variações propostas por pesquisadores desde o aparecimento da primeira versão do algoritmo. Nesse mesmo trabalho é apresentada uma sugestão de padronização para métodos baseados em PSO, reunindo várias características que

melhoram o desempenho da técnica PSO original. Essa versão do algoritmo tem sido chamada de PSO padrão 2007 (*Standard PSO 2007*, em inglês).

A variação mais importante envolve alteração da topologia global do enxame de partículas para uma topologia local. Nessa abordagem, apresentada pela primeira vez em Eberhart e Kennedy (1995), a melhor solução global \mathbf{p}_g na Equação (3.3) é substituída por $\mathbf{p}_l \in \mathbb{R}^d$, a melhor solução da vizinhança, ou seja, a melhor solução dentro de um subconjunto de partículas. No caso em que uma partícula se comunica somente com as duas partículas adjacentes a ela, tem-se uma topologia de enxame com formato de anel.

As Figuras 3.1 e 3.2 fazem uma comparação visual entre as duas topologias (BRATTON; KENNEDY, 2007).

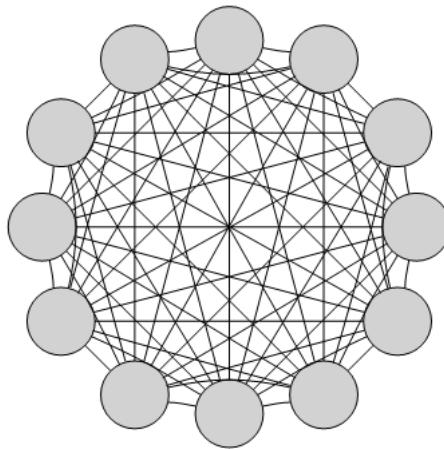


Figura 3.1: Topologia global de enxame para a técnica PSO.

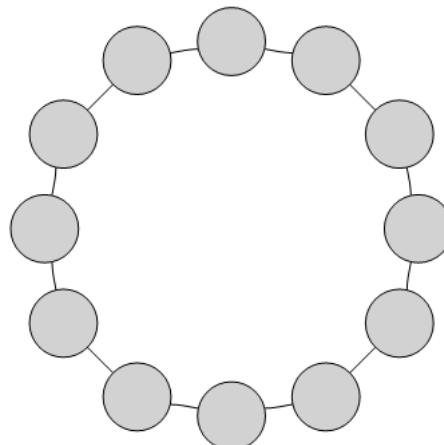


Figura 3.2: Topologia local de enxame para a técnica PSO.

A topologia local apresenta uma convergência mais lenta que a topologia global, pois a troca de informação ocorre em pequenos grupos de partículas, ocasionando a formação de vários grupos de busca inicialmente separados. Entretanto, essa característica permite à versão local do PSO evitar a convergência em um sub-ótimo local indesejável. Nesta monografia as duas topologias serão utilizadas para efeito de comparação.

A técnica PSO padrão 2007 estabelece ainda o uso de um fator de constrição tal qual o apresentado em Clerc e Kennedy (2002), dado por:

$$\chi = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|}, \text{ em que } \varphi = c_1 + c_2. \quad (3.4)$$

Este fator concede mais estabilidade ao algoritmo, proporcionando um equilíbrio entre a busca local de cada partícula e a comunicação com as partículas vizinhas. O fator χ é utilizado na Equação (3.2), multiplicando toda a expressão. Realizando ainda a substituição de \mathbf{p}_g por \mathbf{p}_l , a expressão passa a ser apresentada como:

$$v_{i,j}(k+1) = \chi \{ v_{i,j}(k) + c_1 r_1 (p_{i,j} - x_{i,j}(k)) + c_2 r_2 (p_{l,j} - x_{i,j}(k)) \}, \quad j = 1, 2, \dots, d. \quad (3.5)$$

3.5 Otimização com restrições

Outra característica comumente encontradas nos problemas de otimização na engenharia é a presença de restrições aos atributos que compõem uma possível solução. Essas restrições podem somente determinar um intervalo que o valor de uma dada variável pode assumir ou representar uma relação existente entre duas ou mais variáveis que deve ser respeitada.

A descrição formal de um problema de otimização foi feita na Seção 3.1. No caso da necessidade de minimizar uma função-objetivo $f(\mathbf{x})$ na qual existe uma série de restrições a serem seguidas, pode-se reformular o problema da seguinte forma

simplificada:

$$\text{Minimizar } f(\mathbf{x}) \quad (3.6)$$

$$\text{Sujeito a } g_i(\mathbf{x}) \leq 0, \quad i = 1, 2, \dots, I \quad (3.7)$$

$$h_j(\mathbf{x}) = 0, \quad j = 1, 2, \dots, J \quad (3.8)$$

É comum reescrever cada igualdade $h_j(\mathbf{x}) = 0$ em (3.8) como duas inequações, $h_j(\mathbf{x}) \leq \delta$ e $h_j(\mathbf{x}) \geq \delta$, em que δ é uma constante positiva pequena.

Algoritmos de otimização como a técnica PSO original não lidam com restrições na sua heurística de busca. Apesar disso, há diversas maneiras de introduzir restrições em PSO ou em outros métodos de otimização estocástica. Uma das estratégias mais comuns consiste em criar uma função de penalidade que incorpore à função-objetivo as violações de restrições de uma dada solução. A nova função-objetivo passaria a ser dada por:

$$F(\mathbf{x}) = f(\mathbf{x}) + \sum_j w_j G_j, \quad (3.9)$$

em que, G_j indica o nível de violação da j -ésima restrição enquanto w_j representa o fator de penalidade da mesma.

Dessa forma, o problema poderia ser tratado como no caso sem restrições, fazendo a função-objetivo ser $F(\mathbf{x})$. O principal problema dessa alternativa está no processo de encontrar bons valores para os fatores de penalidade presentes no novo termo adicionado, pois estes são específicos para cada problema.

3.6 Avaliação de soluções com restrições

Em He e Wang (2007) é proposta uma forma de minimizar as dificuldades de lidar com restrições no PSO a partir de uma mudança na regra de avaliação de soluções. Tal regra foi inspirada em idéias incorporadas a métodos AG em Deb (2000) e pode ser resumida pelas seguintes sentenças:

- Toda solução viável (sem violações de restrições) é preferível a qualquer solução inviável (com alguma violação de restrição).
- Entre duas soluções viáveis, aquela com melhor avaliação pela função-objetivo é preferida.

- Entre duas soluções inviáveis, aquela com menos violações é preferida.

Pode-se perceber que se trata de uma extensão à regra original da técnica PSO para busca no espaço de soluções.

É importante perceber a partir dessas novas regras que a Equação (3.9) não será mais necessária. De fato, utiliza-se separadamente o valor da função objetivo e o valor da soma das violações de uma possível solução. Por causa dessa separação dos termos, os fatores de penalidade não são mais necessários. Além disso, as regras propostas forçam a saída das partículas de regiões inviáveis e concentram a busca em espaços com boas soluções.

3.7 Algoritmos metaheurísticos híbridos

Com o crescimento da utilização da técnica PSO, várias formas de hibridização foram propostas, buscando reduzir o efeito de características indesejáveis do algoritmo original, como a dependência de parâmetros reguláveis e a possibilidade de convergência prematura a partir da supervalorização de uma solução específica. Como exemplos podem ser citados a utilização de PSO com AG em Kim, Abraham e Hirota (2007), com elementos de Lógica Fuzzy em Liu e Abraham (2007), com ACO em Holden e Freitas (2008) e com busca caótica em Liu *et al.* (2005).

Comumente técnicas híbridas apresentam estrutura geral determinada por uma metaheurística específica enquanto utilizam outros algoritmos, também metaheurísticos, para realizar procedimentos de busca local e garantir um equilíbrio entre exploração e exploração.

3.7.1 Recozimento Simulado

O algoritmo de otimização SA proposto em Kirkpatrick *et al.* (1983), segue uma analogia ao processo de recozimento utilizado na metalurgia, onde um sólido é inicialmente fundido a uma alta temperatura e em seguida passa por uma lenta etapa de resfriamento que volta a solidificar o material. No primeiro momento os átomos do sólido recebem energia suficiente para se movimentarem mais livremente, enquanto o resfriamento lento resulta na diminuição da movimentação desses átomos que, ao final de todo o processo, passam a ocupar posições com energia mínima.

Na otimização feita por SA, assim como no conhecido algoritmo *Hill Climbing*, novas soluções são geradas aleatoriamente e a solução atual é trocada pela nova caso esta seja melhor. A diferença está na existência de uma probabilidade de aceitação de uma solução pior que a atual. Essa probabilidade é regida por uma temperatura controlada de forma a causar uma chance cada vez menor de se escolher soluções piores. Assim, no início do algoritmo a troca de soluções é freqüente, enquanto ao final torna-se mais difícil de ocorrer. Essa técnica evita a escolha de uma solução sub-ótima logo no início da otimização, permitindo uma melhoria na qualidade da solução final.

3.7.2 Algoritmo PSO Híbrido (HPSO)

Nesta seção é descrito um algoritmo que busca reunir as boas características de duas técnicas metaheurísticas já mencionadas, PSO e SA.

Atualização das melhores soluções encontradas

O algoritmo PSO híbrido (HPSO - *Hybrid Particles Swarm Optimization*, em inglês) descrito em He e Wang (2007) se inicia de forma semelhante ao PSO original descrito na Seção 3.4. Entretanto, no momento de atualização da melhor solução histórica encontrada por cada partícula, aplica-se as regras da Seção 3.6. Considerando $\mathbf{x}_i(k+1)$ a solução atual da i -ésima partícula e $\mathbf{p}_i(k)$ a melhor solução encontrada por essa partícula até então, tem-se que $\mathbf{p}_i(k+1) = \mathbf{x}_i(k+1)$ somente se uma das seguintes condições forem verdadeiras:

- $\mathbf{p}_i(k)$ é inviável e $\mathbf{x}_i(k+1)$ é viável.
- Tanto $\mathbf{p}_i(k)$ quanto $\mathbf{x}_i(k+1)$ são viáveis, mas $f(\mathbf{x}_i(k+1)) < f(\mathbf{p}_i(k))$.
- Tanto $\mathbf{p}_i(k)$ quanto $\mathbf{x}_i(k+1)$ são inviáveis, mas $viol(\mathbf{x}_i(k+1)) < viol(\mathbf{p}_i(k))$.

A cada iteração a melhor solução global, ou a melhor solução da vizinhança, no caso da topologia local, é atualizada de forma semelhante.

A função de nível de violações $viol(\mathbf{x})$ é escrita da seguinte forma:

$$viol(\mathbf{x}) = \sum_j \max(g_j(\mathbf{x}), 0). \quad (3.10)$$

Como as restrições g_j são escritas como visto na Equação (3.7), valores negativos não constituem violações e não afetarão o somatório na Equação (3.10).

Busca local utilizando SA

A estagnação do processo de busca em ótimos locais é um fenômeno algumas vezes presenciado nos algoritmos de populações. Em contrapartida, tais técnicas costumam apresentar vasta exploração no espaço de soluções, principalmente no início de sua execução, além de se beneficiarem da troca de informação entre elementos da população.

A partir dessas idéias e da tendência de hibridização comentada na Seção 3.7, percebe-se a vantagem em incorporar o sistema de busca do SA em um algoritmo de populações, buscando somar as qualidades e reduzir as deficiências.

O algoritmo HPSO, como descrito em He e Wang (2007), adiciona a cada geração uma busca local na melhor solução global encontrada utilizando SA e a regra de avaliação de solução modificada apresentada na Subseção 3.7.2.

Sejam $\mathbf{p}_g \in \mathbb{R}^d$ a melhor solução global encontrada até a geração k e $p_a \in [0, 1]$ a probabilidade de aceitação de uma nova solução. Sejam ainda $\mathbf{X}_{max} \in \mathbb{R}^d$ e $\mathbf{X}_{min} \in \mathbb{R}^d$ vetores correspondentes, respectivamente, aos maiores e menores valores possíveis para as variáveis que compõem uma solução para o problema, $N(0, 1)$ um número pseudo-aleatório com distribuição normal, média zero e variância unitária e $U[0, 1]$ um número pseudo-aleatório uniformemente distribuído entre 0 e 1. Considerando-se η um passo de controle para a geração de soluções, L o número de iterações de duração da busca local e $t(k)$ o parâmetro de temperatura do algoritmo durante a geração k , tem-se à seguinte descrição para a técnica:

Passo 1 Fazer $m = 1$ e $\mathbf{p}'_g = \mathbf{p}_g(k)$.

Passo 2 Gerar uma nova solução a partir da equação abaixo:

$$\mathbf{x}' = \mathbf{p}'_g + \eta(\mathbf{X}_{max} - \mathbf{X}_{min})N(0, 1). \quad (3.11)$$

Passo 3 Calcular p_a de acordo com os seguintes critérios:

- Se \mathbf{x}' é viável e \mathbf{p}'_g é inviável, $p_a = 1$.
- Se \mathbf{x}' é inviável e \mathbf{p}'_g é viável, $p_a = 0$.

- Se \mathbf{x}' e \mathbf{p}'_g são viáveis, calcular p_a pela seguinte equação:

$$p_a = \min \left\{ 1, \exp \left[\frac{f(\mathbf{p}'_g) - f(\mathbf{x}')}{t(k)} \right] \right\}. \quad (3.12)$$

- Se \mathbf{x}' e \mathbf{p}'_g são inviáveis, calcular p_a pela seguinte equação:

$$p_a = \min \left\{ 1, \exp \left[\frac{\text{viol}(\mathbf{p}'_g) - \text{viol}(\mathbf{x}')}{t(k)} \right] \right\}. \quad (3.13)$$

Passo 4 Se $p_a \geq U[0, 1]$, $\mathbf{p}'_g = \mathbf{x}'$.

Passo 5 Fazer $m = m + 1$. Se $m \geq L$, interromper a busca e a nova melhor solução global passa a ser \mathbf{p}'_g . Caso contrário, ir para o Passo 2.

Durante a execução do algoritmo, o seguinte valor empírico para a temperatura inicial é utilizado (HE; WANG, 2007):

$$t_0 = -\frac{f_{\max} - f_{\min}}{\ln(0.1)}, \quad (3.14)$$

em que f_{\max} e f_{\min} são o maior e o menor valor da função-objetivo encontrados no enxame inicial de partículas. O processo de redução de temperatura escolhido é o exponencial, ou seja, $t(k+1) = \lambda t(k)$, na qual a taxa de recozimento λ satisfaz $0 < \lambda < 1$.

Nesta monografia, no caso da topologia local de enxame, a mesma abordagem de busca local é utilizada na melhor solução de uma dada vizinhança. Entretanto, para diminuir o esforço computacional, apenas uma parte das vizinhanças é escolhida aleatoriamente a cada iteração para a realização desse passo do algoritmo.

3.7.3 HPSO como método de solução de problemas de RRM

No Capítulo 2 foi mostrada uma maneira de organização dos parâmetros do problema. O vetor mostrado na Figura 2.5 pode ser visto como um modelo para as partículas que formarão o enxame do algoritmo de otimização.

O Fluxograma 3.3 indica os passos do algoritmo HPSO com topologia global, enquanto a topologia local é detalhada no Fluxograma 3.4. O processo de busca local através da técnica SA é representado em 3.5. Nos fluxogramas apresentados, G_{\max} é o número máximo de gerações e k é a geração atual. No caso da topologia local,

$numParticles$ é o número de partículas do enxame e a constante $taxaBuscaLocal$ indica a parcela de vizinhanças nas quais serão aplicadas a busca local.

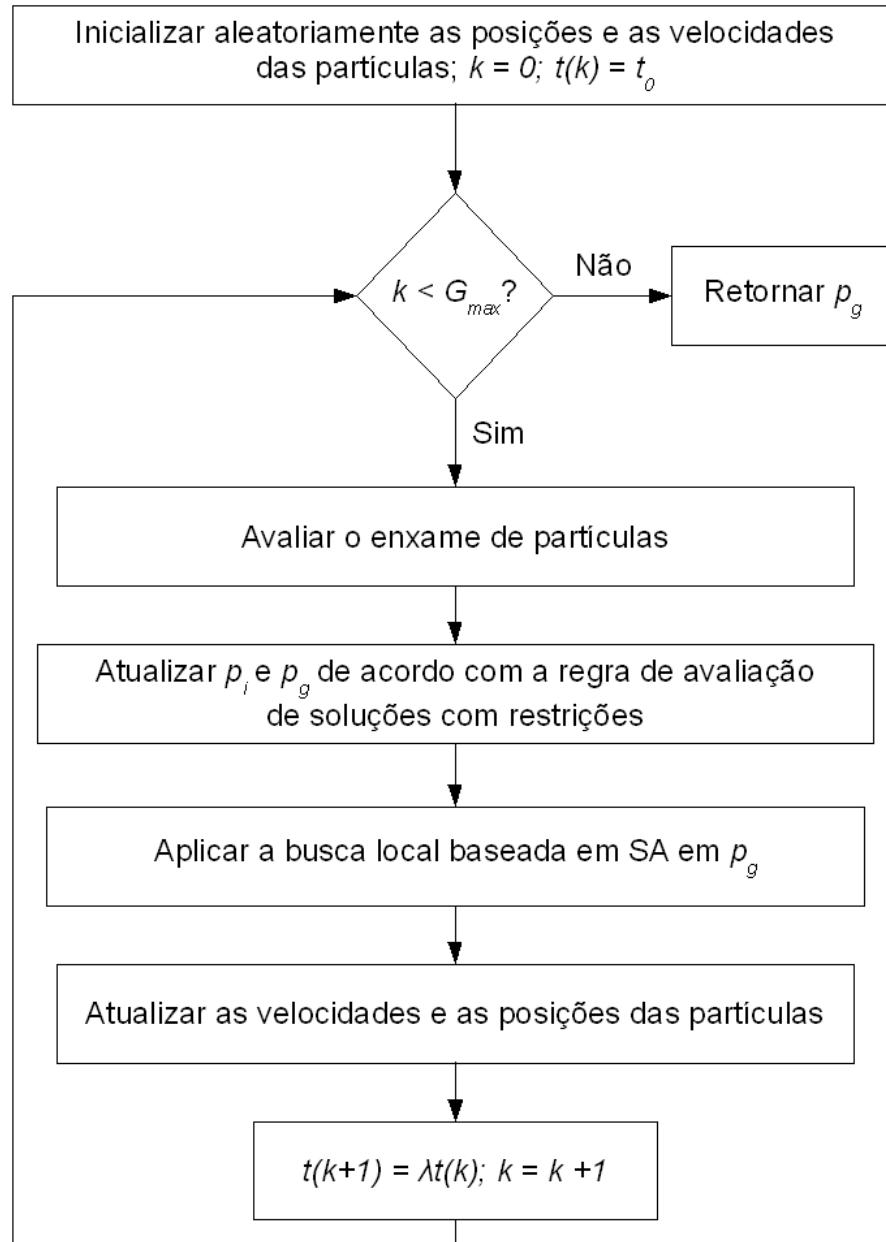


Figura 3.3: Fluxograma para algoritmo HPSO com topologia global.

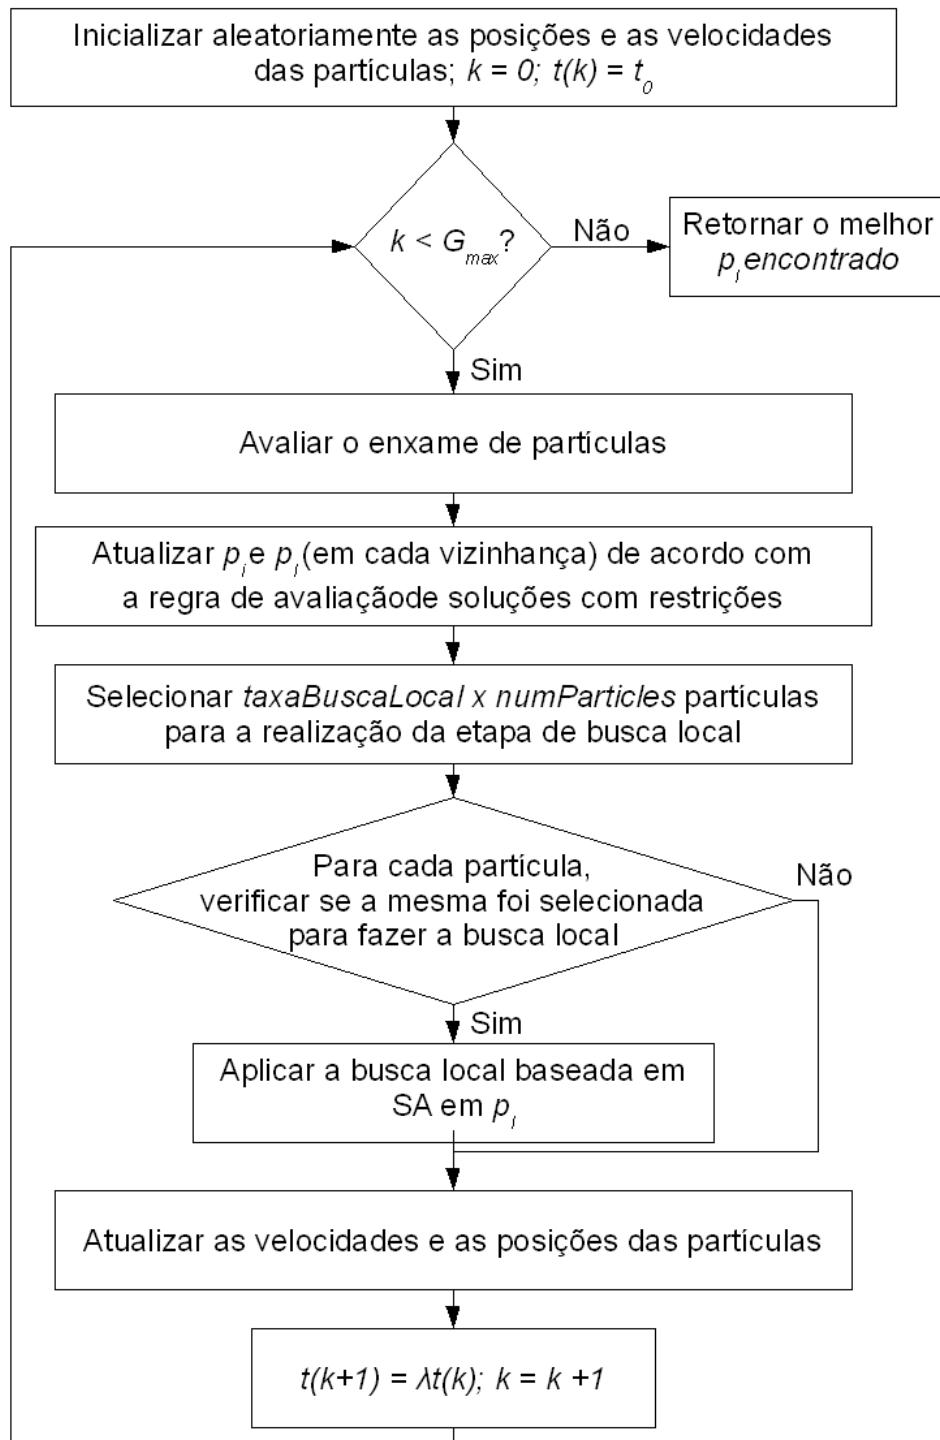


Figura 3.4: Fluxograma para algoritmo HPSO com topologia local.

3.8 Conclusões

Neste capítulo o problema de otimização com restrições foi detalhado e uma estratégia de solução baseada em técnicas metaheurísticas foi apresentada.

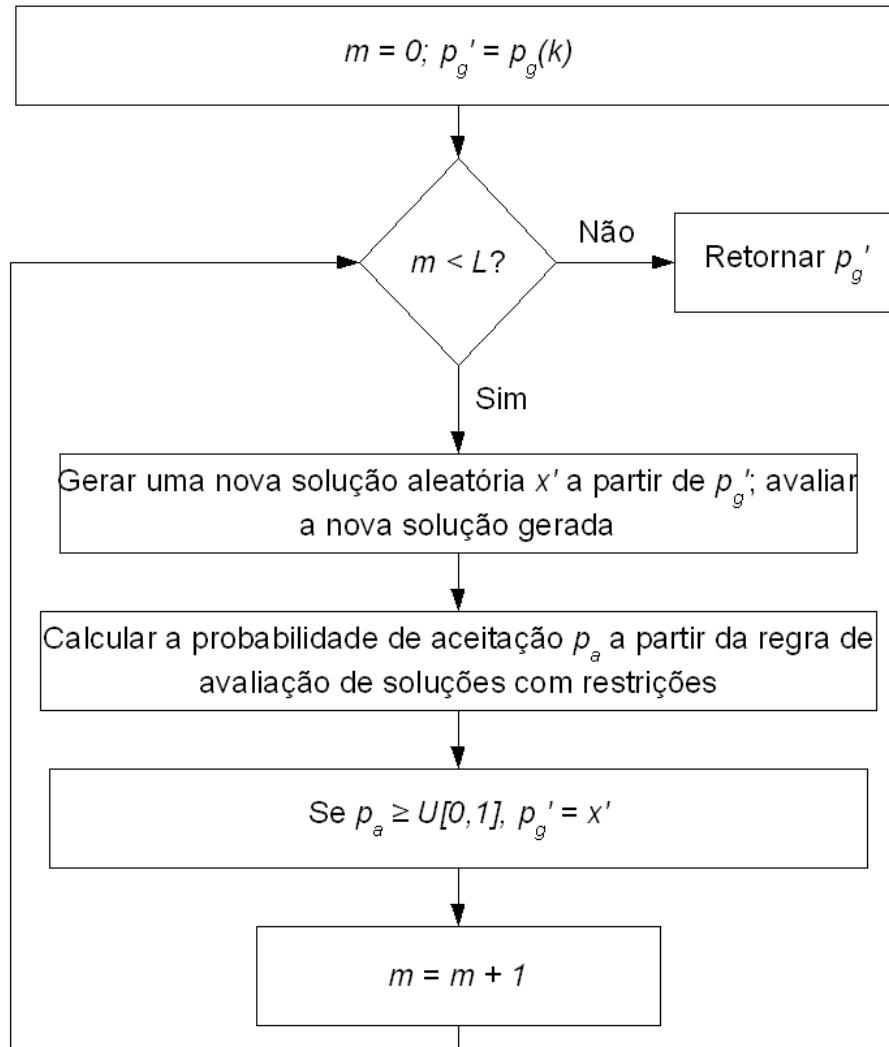


Figura 3.5: Fluxograma para busca local por SA.

O algoritmo PSO original foi descrito, assim como suas variações introduzidas pela versão padrão 2007, pelas regras de avaliação de soluções com restrições e pela hibridização com a técnica SA. Foram estudados ainda as topologias mais comuns

de organização do enxame de partículas e os mecanismos utilizados pelo método PSO para explorar o espaço de soluções de maneira eficiente.

No próximo capítulo serão apresentados os resultados obtidos com a aplicação da ferramenta de otimização metaheurística híbrida HPSO no problema de gerência de recursos de rádio que detalhamos no Capítulo 2.

Análise dos Resultados

Neste capítulo são apresentados os resultados obtidos com a utilização do algoritmo descrito no Capítulo 3, assim como os parâmetros escolhidos para a realização das simulações.

4.1 Parâmetros do modelo de alocação de recursos

O modelo do problema de alocação de recursos de rádio apresentado no Capítulo 2 é válido para diversos cenários de aplicação de redes WCDMA. Entretanto, para efeito de simulação, alguns parâmetros da rede precisam ser determinados.

Na Equação (2.20) para a perda de percurso, serão utilizados os valores $G_{ant} = 18dBi$, $R_{cell} = 500m$, $n_{loss} = 3,5$, $L_0 = R$, $P_{L0} = 100dB$ e desvio padrão $\sigma = 8dB$.

As características da célula WCDMA utilizadas na Equação (2.12) serão $W = 5MHz$ e $pt_n = -110dB$. Nas Equações (2.24), (2.25) e (2.26) serão fixados, caso não seja observado outros valores, $r_{max} = 600Kbps$, $pt_{ERB} = 43dBm$ e $\frac{E_b}{N_0} = 7dB$. O valor utilizado para a interferência externa será de metade da interna, aproximação comumente aplicada (NETO; CAVALCANTI, 2007).

A função de aceitação, representada pela Equação (2.7), será utilizada com os parâmetros $C = 0,05$, $\mu = 2$ e $\epsilon = 4$.

A função de utilidade, vista na Equação (2.3), apresentará α aleatório uniformemente distribuído entre 2 e 5, enquanto o parâmetro β varia uniformemente entre $100kbps$ e $300kbps$.

Parâmetro	Valor utilizado
Raio da célula (R_{cell})	500m
Ganho de antena (G_{ant})	18dBi
Expoente de perda de percurso (n_{loss})	3,5
Distância de referência para perda de percurso (L_0)	R
Perda de percurso de referência (P_{L0})	100dB
Desvio padrão do sombreamento (σ)	8dB
Banda total disponível (W)	5MHz
Potência do ruído (pt_n)	-110dB
Máxima quantidade de recursos alocada por usuário (r_{max})	600Kbps
Potência disponível na ERB (pt_{ERB})	43dBm
SINR alvo ($\frac{E_b}{N_0}$)	7dB
Parâmetro C da função de Aceitação	0,05
Parâmetro μ da função de Aceitação	2
Parâmetro ϵ da função de Aceitação	4
Intervalo do parâmetro α da função de Utilidade	[2,5]
Intervalo do parâmetro β da função de Utilidade	[100,300]Kbps

Tabela 4.1: Parâmetros do modelo de alocação de recursos.

A Tabela 4.1 resume os parâmetros do modelo estudado.

4.2 Parâmetros do processo de otimização

Antes das simulações referentes ao processo de otimização serem realizadas, deve-se determinar alguns parâmetros que serão utilizados. Algumas escolhas são empíricas, feitas após vários testes comparativos. Em outros casos, certos valores são propostos por vários autores como aceitáveis para uma grande quantidade de problemas.

4.2.1 Parâmetros da etapa PSO

Na versão do método PSO padrão 2007 sugere-se que o enxame de otimização possua entre 20 e 100 partículas (BRATTON; KENNEDY, 2007). Após alguns testes, escolheu-se para esta monografia o uso de 50 partículas para ambas as topologias implementadas.

Parâmetros	Valor utilizado
Número de partículas	50
Número de gerações	500
Fator de constrição (χ)	0,72984
Coeficientes aceleradores ($c_1 = c_2$)	2
Velocidade máxima das partículas (V_{max})	$0,5(X_{max} - X_{min})$

Tabela 4.2: Parâmetros da etapa de PSO.

O número de gerações foi limitado a 500 para ambas as topologias, sendo o número máximo de gerações a única condição de parada dos testes realizados. Em diversos casos o algoritmo converge em uma quantidade menor de gerações, mas optou-se por uma margem maior para convergência.

O fator de constrição χ , já comentado na Seção 3.4.2, será utilizado para oferecer maior estabilidade ao algoritmo. Vários autores, assim como em Bratton e Kennedy (2007), utilizam na Equação (3.4) os valores $c_1 = c_2 = 2,05$, resultando em $\varphi = 4,1$ e $\chi \approx 0,72984$. Esses também serão os valores adotados nesta monografia.

Em Eberhart e Shi (2000) é ressaltada a importância do uso do fator de constrição juntamente com a limitação da velocidade máxima possível para as partículas. É sugerido o limite $V_{max} = X_{max} - X_{min}$ para cada dimensão no espaço de soluções, sendo X_{max} e X_{min} respectivamente os maiores e os menores valores possíveis para uma dada variável do problema. Entretanto, após alguns testes, foi percebido que a escolha $V_{max} = 0,5(X_{max} - X_{min})$ apresenta resultados ligeiramente superiores e, por esse motivo, será a utilizada nesta monografia.

A atitude tomada para partículas que tentem sair do espaço de soluções viáveis será a de limitar sua posição à fronteira do espaço permitido e tornar sua velocidade nula na dimensão extrapolada. Essa medida permite que as demais partículas do enxame atraiam a partícula em questão para regiões com melhores soluções.

Os intervalos fixados para as variáveis do problema serão $pt \in [0, pt_{ERB}]$ para a potência alocada, $p \in [0,1, 0,8]$ para o caso de preço constante e $k \in [10^{-6}, 10^{-2}]$ para o caso de cobrança linear.

Os principais parâmetros utilizados no processo de otimização durante a etapa de PSO estão resumidos na Tabela 4.2.

Parâmetros	Valor utilizado
Número de iterações (L)	20
Taxa de reconhecimento (λ)	0,94
Passo de incremento (η)	0,001
Parcela de vizinhanças com busca local (topologia local)	10%

Tabela 4.3: Parâmetros da etapa de SA.

4.2.2 Parâmetros da etapa de SA

Sugere-se em He e Wang (2007) 20 iterações de busca local durante a etapa de SA do HPSO, além de uma taxa de reconhecimento de 0,94 e um passo de incremento de 0,001. Nesta monografia utilizou-se esses mesmos valores.

Como anunciado no Capítulo 3, na versão do algoritmo com topologia local limitou-se o número de vizinhanças nas quais é utilizada a busca local da técnica HPSO, procurando reduzir o esforço computacional. Testes realizados mostraram que aplicar a técnica SA em 10% dos subgrupos é suficiente para a obtenção de soluções aceitáveis.

A Tabela 4.3 resume os parâmetros utilizados na etapa de busca local do processo de otimização.

4.3 Ambiente de testes

Todas as simulações foram realizadas utilizando o *software* livre Scilab versão 5.0.3 em ambiente computacional *Pentium D* de 2,8GHz e 2GB de memória RAM.

Uma interface gráfica simples foi construída para facilitar as etapas de testes dos *scripts* desenvolvidos. A Figura 4.1 ilustra a interface do ambiente de testes.

Cada teste consiste de 20 realizações independentes do algoritmo. Em seguida são calculadas métricas estatísticas a partir das soluções encontradas, como função-objetivo média, maior e menor função-objetivo, desvio padrão das soluções, função utilidade média, função aceitação média e tempo de execução médio.

4.4 Resultados obtidos

Nesta seção os resultados das simulações realizadas serão apresentados. Nas subseções a seguir modifica-se alguns parâmetros do modelo para observar os efeitos

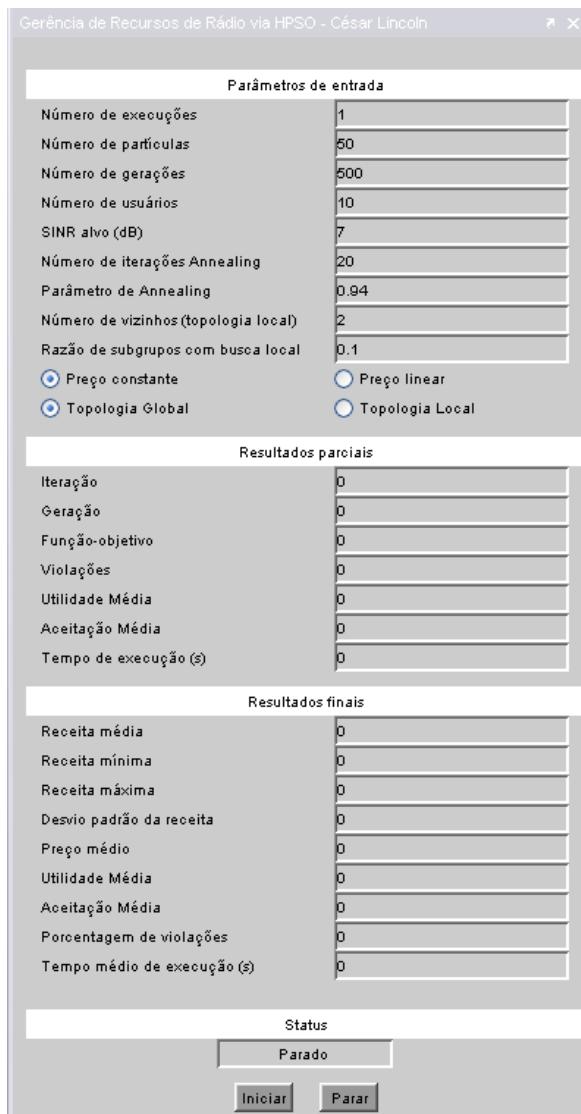


Figura 4.1: Interface gráfica do ambiente de testes.

causados no processo de otimização. Em cada subseção é utilizado um cenário próprio de testes, com perfis e localizações de usuários distintos, não sendo relevante comparar resultados de subseções diferentes.

4.4.1 Variação com número de usuários

As tabelas a seguir referem-se aos testes realizados variando-se a quantidade de terminais na célula WCDMA. Foram utilizados os valores de 8, 10, 12 e 14 usuários.

Em cada caso são observados os valores obtidos com as duas topologias estudadas, global e local, e com os dois modelos de tarifação apresentados, constante e linear.

Pode-se perceber que em relação à qualidade e à variabilidade das soluções

	Topologia Global	Topologia Local
Número de usuários	8	8
Receita média	2,710153	2,7108592
Receita mínima	2,7077066	2,7107328
Receita máxima	2,7108435	2,7109269
Desvio padrão da receita	0,0008223	0,0000542
Preço médio	0,3751220	0,3753547
Utilidade média	0,9630467	0,9634837
Aceitação média	0,9030986	0,9027669
Tempo de execução (em segundos)	16,99225	44,54145

Tabela 4.4: Resultados obtidos para 8 usuários e tarifação constante.

	Topologia Global	Topologia Local
Número de usuários	8	8
Receita média	2,6367899	2,6367869
Receita mínima	2,6367898	2,6367349
Receita máxima	2,6367899	2,6367899
Desvio padrão da receita	10^{-8}	0,0000123
Valor médio de k para tarifação	0,0008691	0,0008691
Utilidade média	0,9177273	0,9177084
Aceitação média	0,9006065	0,9005820
Tempo de execução (em segundos)	17,01865	44,71345

Tabela 4.5: Resultados obtidos para 8 usuários e tarifação linear.

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita média	3,2130372	3,2945576
Receita mínima	3,0209672	3,0209903
Receita máxima	3,3089609	3,3089613
Desvio padrão da receita	0,1344211	0,0643911
Preço médio	0,3690467	0,3670976
Utilidade média	0,8986934	0,9167750
Aceitação média	0,8709897	0,8975206
Tempo de execução (em segundos)	19,61875	50,50385

Tabela 4.6: Resultados obtidos para 10 usuários e tarifação constante.

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita média	3,0478566	3,0478418
Receita mínima	3,0478329	3,0477985
Receita máxima	3,0478585	3,0478584
Desvio padrão da receita	0,0000057	0,0000166
Valor médio de k para tarifação	0,0011571	0,0011572
Utilidade média	0,8323622	0,8324535
Aceitação média	0,8793007	0,8791619
Tempo de execução (em segundos)	19,65395	50,72795

Tabela 4.7: Resultados obtidos para 10 usuários e tarifação linear.

	Topologia Global	Topologia Local
Número de usuários	12	12
Receita média	3,4490174	3,6599085
Receita mínima	3,0315539	3,5190963
Receita máxima	3,7148621	3,7148617
Desvio padrão da receita	0,1948287	0,0781883
Preço médio	0,3617827	0,3511893
Utilidade média	0,7887713	0,8153183
Aceitação média	0,7960142	0,8692369
Tempo de execução (em segundos)	22,2217	56,4735

Tabela 4.8: Resultados obtidos para 12 usuários e tarifação constante.

	Topologia Global	Topologia Local
Número de usuários	12	12
Receita média	3,2239533	3,262977
Receita mínima	3,0477228	3,1410802
Receita máxima	3,3218643	3,3218534
Desvio padrão da receita	0,0787723	0,0485920
Valor médio de k para tarifação	0,0011640	0,0011558
Utilidade média	0,7262949	0,7382338
Aceitação média	0,8260827	0,8329657
Tempo de execução (em segundos)	22,21795	56,5929

Tabela 4.9: Resultados obtidos para 12 usuários e tarifação linear.

	Topologia Global	Topologia Local
Número de usuários	14	14
Receita média	3,4957685	3,6483591
Receita mínima	3,0175561	3,1508636
Receita máxima	3,816988	3,8234872
Desvio padrão da receita	0,1961711	0,1668746
Preço médio	0,3570320	0,3434579
Utilidade média	0,6767028	0,6823851
Aceitação média	0,7010900	0,7601745
Tempo de execução (em segundos)	24,7093	62,0838

Tabela 4.10: Resultados obtidos para 14 usuários e tarifação constante.

	Topologia Global	Topologia Local
Número de usuários	14	14
Receita média	3,2500309	3,2982037
Receita mínima	3,0377196	3,2227495
Receita máxima	3,343285	3,3451889
Desvio padrão da receita	0,0805687	0,0406596
Valor médio de k para tarifação	0,0011583	0,0011477
Utilidade média	0,6105109	0,6211182
Aceitação média	0,7684837	0,7553435
Tempo de execução (em segundos)	24,73745	62,23435

Tabela 4.11: Resultados obtidos para 14 usuários e tarifação linear.

geradas, a versão com topologia local, em geral, apresentou resultados melhores. Nota-se ainda que para uma menor quantidade de usuários a receita obtida a cada execução do algoritmo foi bastante semelhante, apresentando desvio padrão reduzido. Este comportamento indica que para cenários mais simples, com recursos em abundância, ambas as topologias do método HPSO se mostraram estáveis.

No caso de uma maior quantidade de usuários, o desvio padrão das soluções aumentou, mas a receita média também foi elevada. Entretanto, este aumento não foi contínuo. Considerando-se somente as simulações realizadas com topologia local e tarifação constante, quando aumentou-se em 25% os usuários, de 8 para 10, a receita média cresceu 21,53%. Já de 10 para 12 usuários, correspondendo a 20% de aumento, a receita média foi 11,09% maior. Com mais 16,67% de aumento, de 12 para 14, a receita média pouco foi alterada, apresentando na verdade uma pequena redução de 0,31% devido a maior variedade das soluções encontradas. O fato da adição de novos terminais não provocar aumento da receita gerada revela que a célula já se encontrava com sua capacidade máxima de recursos alocada.

A maior diferença de qualidade média entre as soluções encontradas pelas duas topologias ocorre na Tabela 4.8, em que a receita média obtida pela topologia local foi 6,11% maior que aquela encontrada pela topologia global. No mesmo caso, a utilidade e aceitação médias foram, respectivamente, 3,37% e 9,20% maiores na versão local. Entretanto, o tempo de execução da versão local foi 2,54 vezes o da versão global.

Quanto às diferenças entre os modelos de tarifação constante e linear, nota-se que a primeira variação de cobrança apresentou soluções superiores, sendo a variação máxima de 12,16% observada nos resultados para a topologia local das Tabelas 4.8 e 4.9.

Entretanto, a política de tarifação constante pode não ser aplicável na prática em alguns cenários. No caso de usuários com necessidades de taxas muito diferentes, os usuários com menor requerimento de recursos podem ser considerados injustiçados, já que pagam o mesmo valor que os usuários que possuem maior requerimento. Cabe à operadora decidir nessa situação o modelo de cobrança mais adequado.

4.4.2 Variação com a SINR alvo

As Tabelas 4.12, 4.13 e 4.14 referem-se aos testes realizados variando-se a SINR alvo do serviço. Foram utilizados os valores de 5dB, 6dB e 7dB.

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita média	3,1126014	3,1488804
Receita mínima	2,8955967	2,9129333
Receita máxima	3,1612988	3,1612988
Desvio padrão da receita	0,1003360	0,0555362
Preço médio	0,3523100	0,3509608
Utilidade média	0,8314504	0,8381305
Aceitação média	0,8838462	0,8973203
Tempo de execução (em segundos)	19,6493	50,65385

Tabela 4.12: Resultados obtidos para 10 usuários e SINR 5dB.

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita média	2,8578721	2,9249851
Receita mínima	2,5772828	2,7775519
Receita máxima	2,9482166	2,9482166
Desvio padrão da receita	0,1114227	0,0574278
Preço médio	0,3344600	0,3299270
Utilidade média	0,7252689	0,7329770
Aceitação média	0,8558162	0,8871300
Tempo de execução (em segundos)	19,5624	50,6828

Tabela 4.13: Resultados obtidos para 10 usuários e SINR 6dB.

Em cada caso são observados os valores obtidos para um cenário com 10 usuários utilizando as duas topologias estudadas, global e local, ambas com tarifação constante.

Pode-se perceber que o aumento da SINR alvo contribui para a queda da receita média obtida, pois causa uma menor alocação de recursos em geral para os terminais. As maiores diferenças de receita média ocorreram nos testes com a topologia global, sendo a versão com SINR de 6dB 15,41% superior à de 7dB e a de 5dB 8,91% superior à de 6dB. De maneira semelhante, para todos os testes a utilidade e aceitação médias foram crescentes com a diminuição da SINR alvo.

O requerimento de uma relação sinal-interferência menor permite que o algoritmo

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita média	2,4762599	2,6209591
Receita mínima	2,1209258	2,5651735
Receita máxima	2,6332128	2,6332128
Desvio padrão da receita	0,1265414	0,0220817
Preço médio	0,3212703	0,3010294
Utilidade média	0,6036403	0,6003136
Aceitação média	0,7741120	0,8723050
Tempo de execução (em segundos)	19,4818	50,6304

Tabela 4.14: Resultados obtidos para 10 usuários e SINR 7dB.

de otimização busque soluções em que as potências alocadas influenciem menos na interferência intra-cellular e possibilitem maiores taxas para cada terminal.

4.4.3 Análise detalhada de alocação de recursos

Nos gráficos a seguir, analisa-se mais detalhadamente o processo de alocação de recursos realizado durante a etapa de otimização via HPSO para ambas as topologias de enxame estudadas. São mostradas a evolução da função-objetivo ao longo das iterações do algoritmo, a comparação entre as taxas requeridas e as alocadas, as potências que compõem a solução encontrada, assim como as funções utilidade e aceitação de cada usuário.

O cenário utilizado para gerar os resultados desta subseção envolve 10 usuários, SINR alvo de 7dB e tarifação constante. As características dos 10 terminais utilizados nos testes desta seção estão resumidos na Tabela 4.15, na qual d_i é a distância do i -ésimo terminal à ERB, θ_i é o coeficiente de correlação cruzada calculado pela Equação (2.14) e β_i é o parâmetro do usuário correspondente na Equação (2.3).

A Tabela 4.16 apresenta os resultados obtidos pelas duas topologias em uma única execução.

Na Figura 4.2 pode ser observado que o algoritmo eliminou as violações das soluções do enxame de partículas em menos de 20 iterações. Antes das 150 iterações o algoritmo convergiu de forma a não obter soluções melhores. É importante notar que a função-objetivo utilizada é a descrita na Equação (2.27), referente ao inverso

	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}
d_i (m)	448	54	10	316	77	362	253	233	167	28
θ_i	0,56	0,14	0,03	0,48	0,18	0,51	0,42	0,40	0,33	0,08
β_i (KHz)	114	158	292	110	200	107	136	246	197	269

Tabela 4.15: Parâmetros do cenário para testes detalhados de alocação de recursos.

	Topologia Global	Topologia Local
Número de usuários	10	10
Receita	2,6833802	3,1924699
Preço	0,3687285	0,3541626
Utilidade média	0,7546654	0,8583537
Aceitação média	0,7218677	0,9014136

Tabela 4.16: Resultados obtidos para 10 usuários e SINR 7dB.

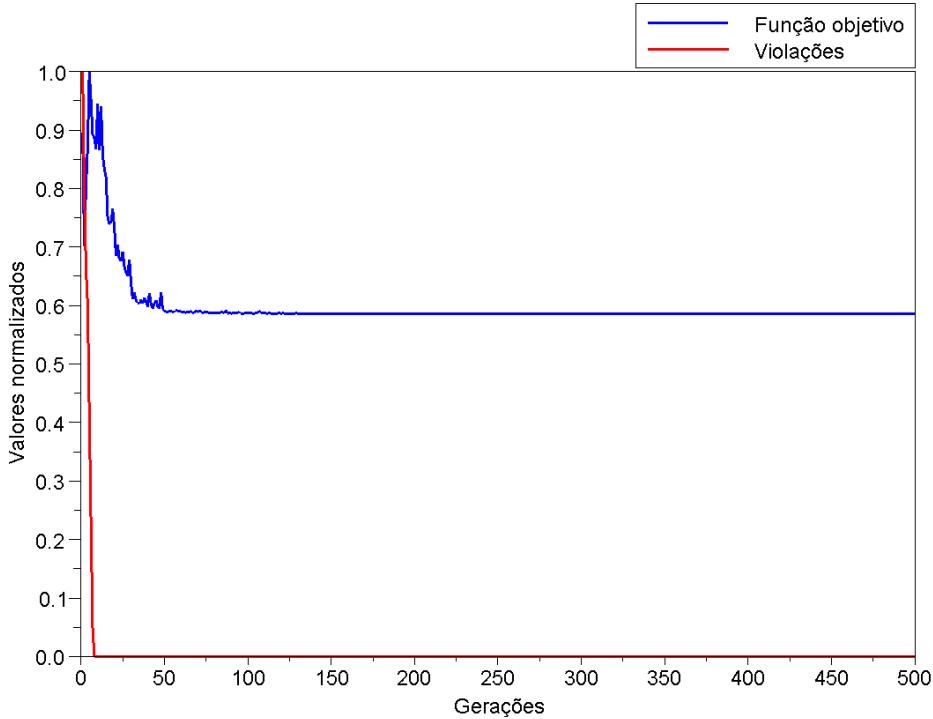


Figura 4.2: Evolução típica da função objetivo e das violações para topologia global.

da receita da operadora.

Nas Figuras 4.3 e 4.4 percebe-se que o algoritmo não alocou quaisquer recursos para o terminal T_8 . Em vez disso, a versão global da técnica maximizou as taxas

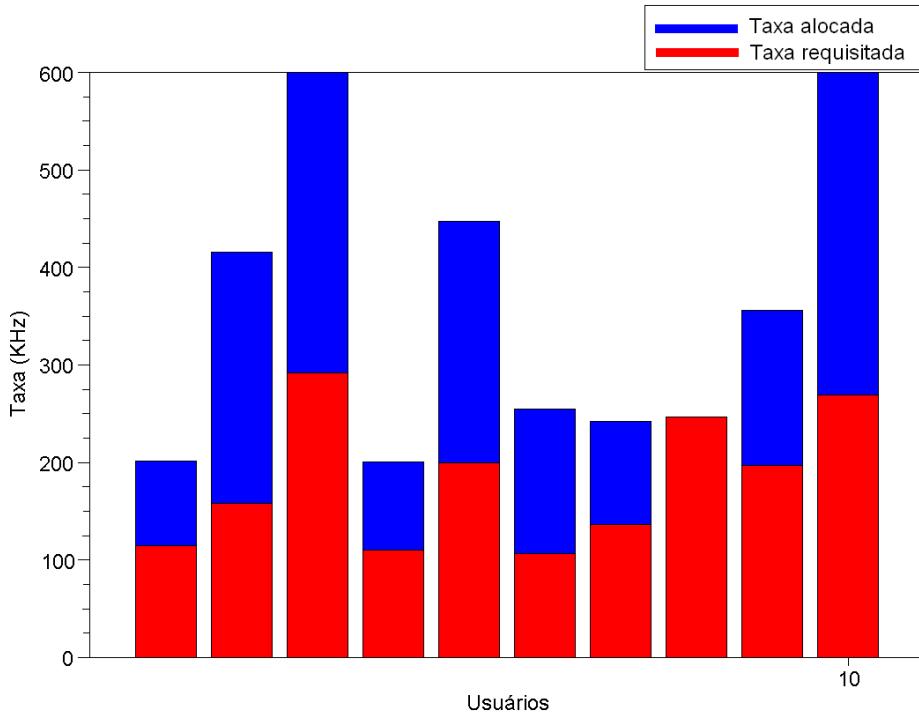


Figura 4.3: Taxa típica alocada para topologia global.

alocadas para os terminais T_3 e T_{10} . Apesar da boa alocação para a maioria dos usuários, a receita, utilidade média e aceitação média obtidas foram reduzidas por tratar-se de uma solução sub-ótima que não envolve alocação de recursos para um terminal.

A Figura 4.7 indica que a topologia local apresentou convergência mais lenta que a global. A eliminação das violações do enxame de partículas ocorreu em 50 iterações e a função-objetivo estabilizou-se em torno das 200 iterações.

Entretanto, as alocações de taxa e potência observadas nas Figuras 4.8 e 4.9 comprova que a distribuição de recursos foi feita de forma mais equilibrada, atendendo às necessidades de todos os usuários. O motivo dos terminais T_3 e T_{10} continuaram a receber maiores taxas é que estes são os mais próximos da ERB, como pode ser conferido na Tabela 4.15. Também por este motivo as potências reservadas para estes terminais foram as menores.

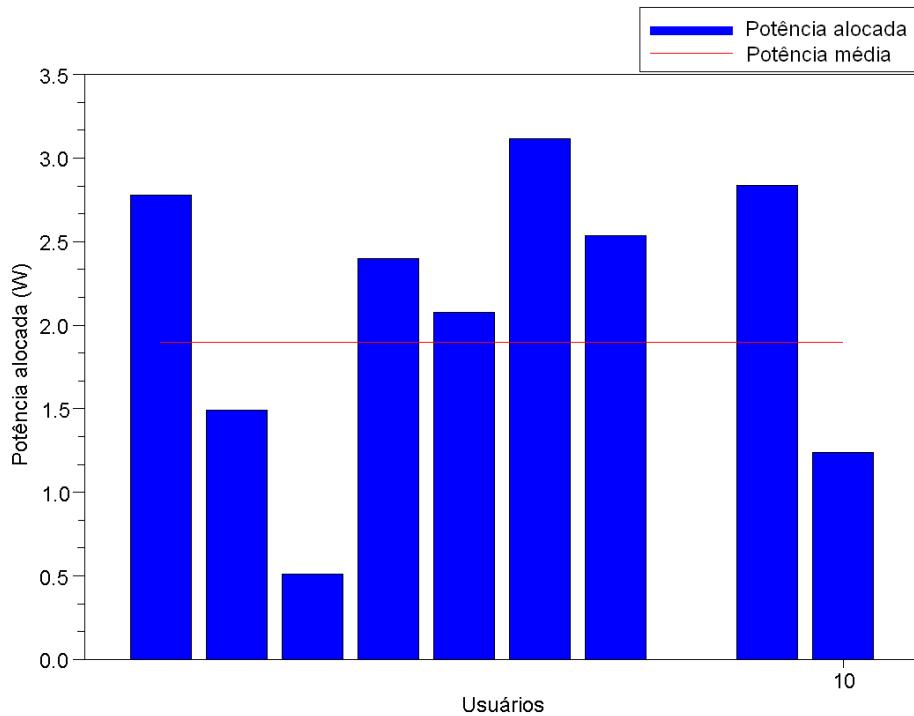


Figura 4.4: Potência típica alocada para topologia global.

4.5 Conclusões

Neste capítulo apresentou-se os parâmetros utilizados nos modelos descritos nos Capítulos 2 e 3, assim como o ambiente de simulação do processo de otimização metaheurística.

Foram realizados diversos testes para avaliar o desempenho da técnica HPSO em diferentes cenários e com as duas topologias de enxame estudadas. Em geral, os resultados obtidos com a topologia local foram superiores, enquanto a topologia global apresentou tempos de execução bem menores para as mesmas quantidades de partículas e de gerações do algoritmo. Dessa forma, caso seja dada prioridade à qualidade da solução, a versão local do método deve ser aplicada. Caso a restrição de tempo seja mais forte, a versão global pode ser utilizada.

É importante notar que os tempos de execução citados neste capítulo devem ser avaliados apenas de forma relativa, já que, na operação de um sistema de comunicação móvel real, os algoritmos de alocação de recursos podem ser compilados e otimizados para o *hardware* apropriado, melhorando consideravelmente sua

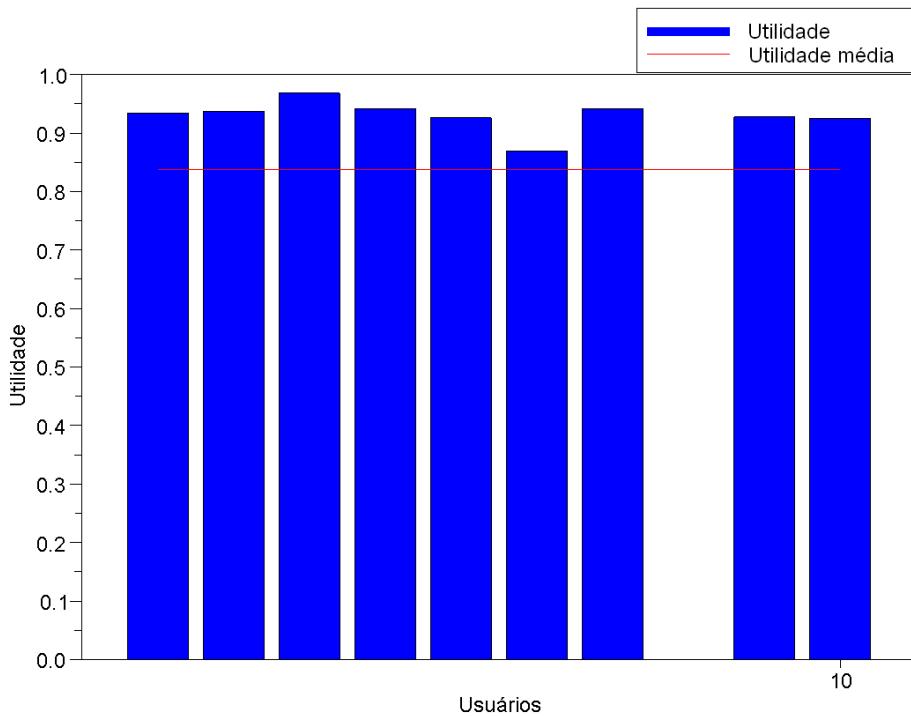


Figura 4.5: Utilidade típica para topologia global.

velocidade de execução.

Em relação à quantidade de usuários na célula observou-se que, apesar da receita média crescer com o número de terminais, existe um limite para o qual a adição de usuários não será mais vantajosa. Este limite deve ser considerado durante as especificações de projeto e operação da célula WCDMA.

Durante os testes realizados observou-se ainda que a SINR alvo é outro parâmetro do sistema que influencia diretamente na receita gerada pela alocação de recursos, assim como nos valores obtidos para a utilidade e aceitação médias. Este comportamento indica que a produção de dispositivos receptores que permitam a mesma qualidade de operação para uma SINR menor resulta no aumento da receita para a fornecedora do serviço de comunicação.

Ao final do capítulo, os resultados do processo de alocação foram apresentados de forma mais detalhada, revelando a característica da versão local do método HPSO de escapar de mínimos locais, ao contrário da versão com topologia global.

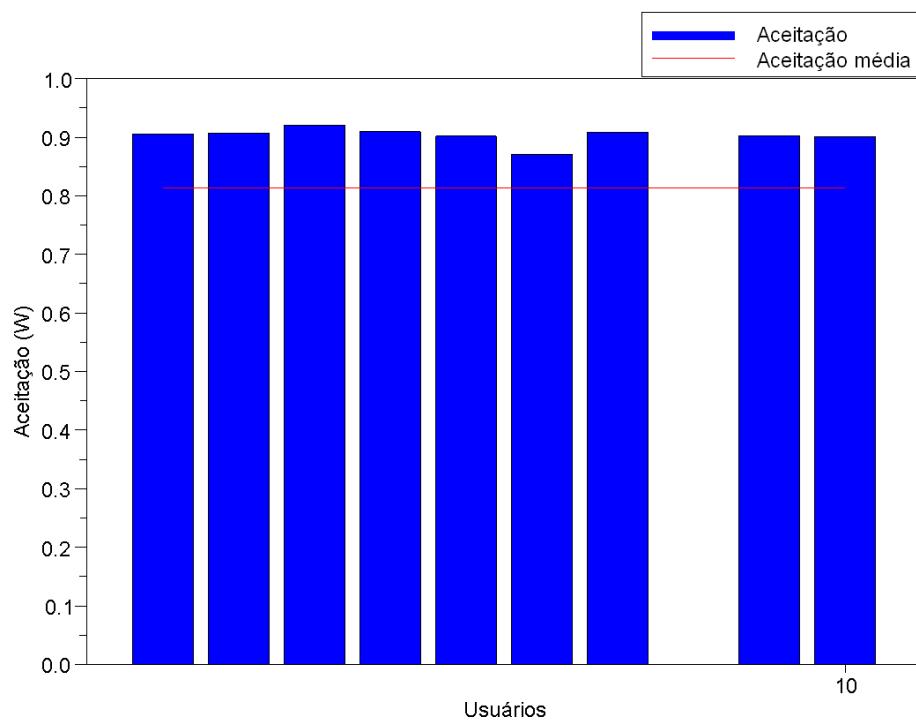


Figura 4.6: Aceitação típica para topologia global.

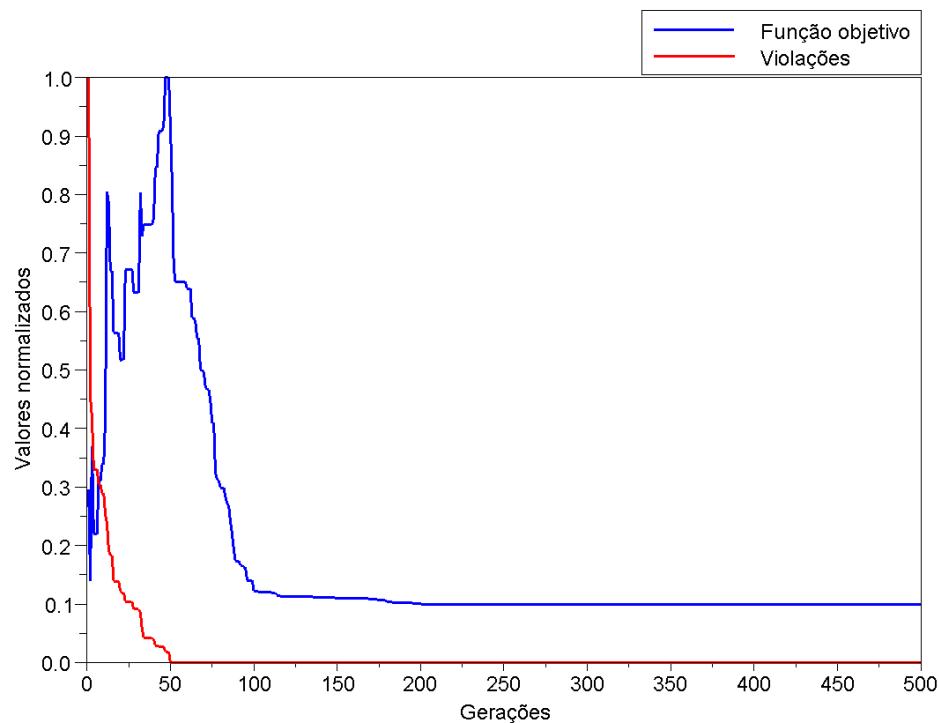


Figura 4.7: Evolução típica da função objetivo e das violações para topologia local.

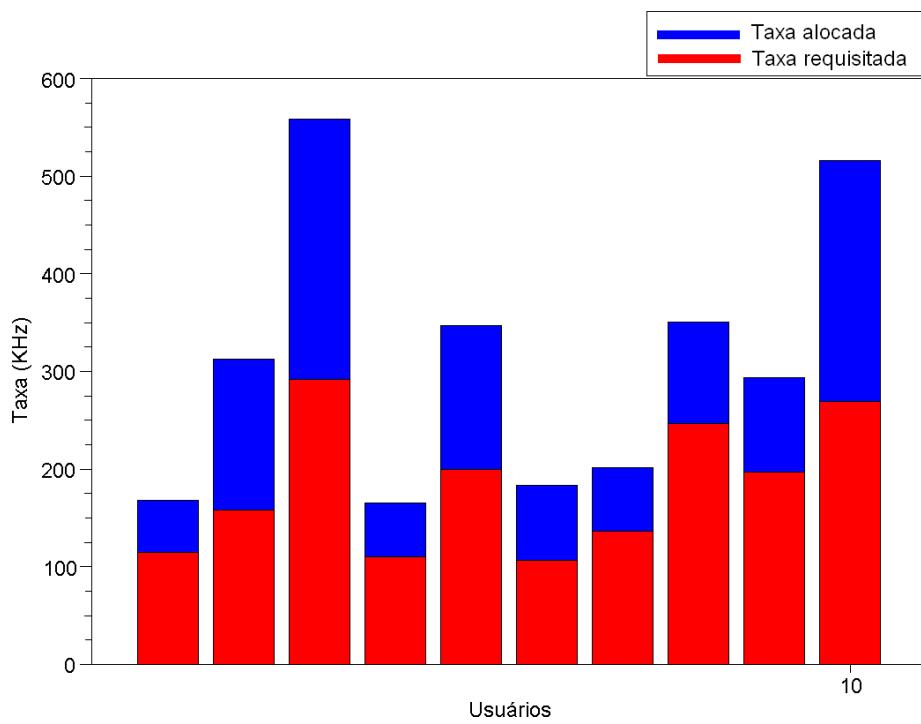


Figura 4.8: Taxa típica alocada para topologia local.

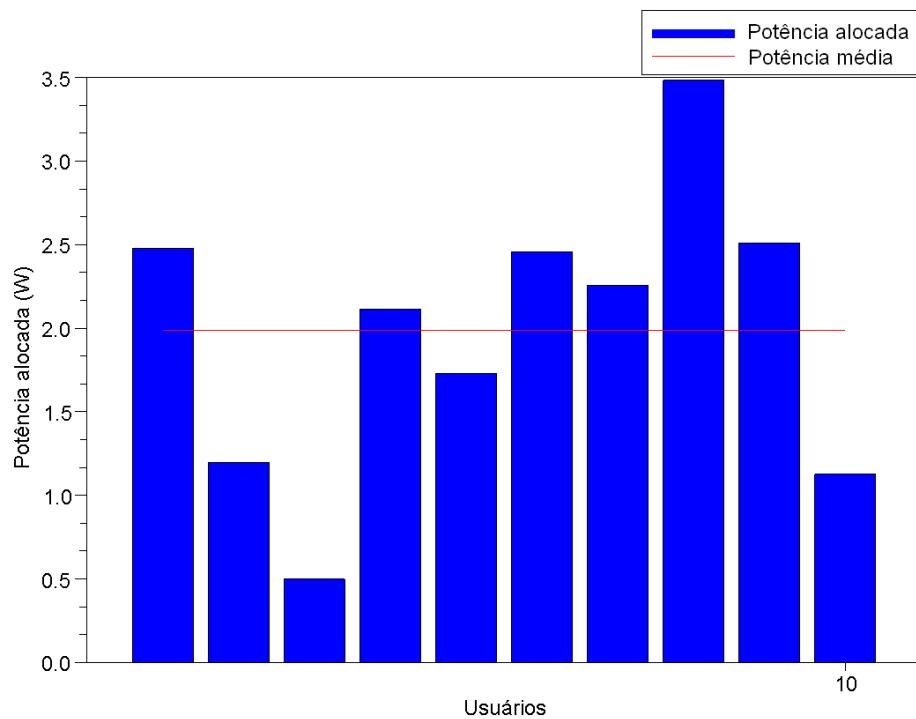


Figura 4.9: Potência típica alocada para topologia local.

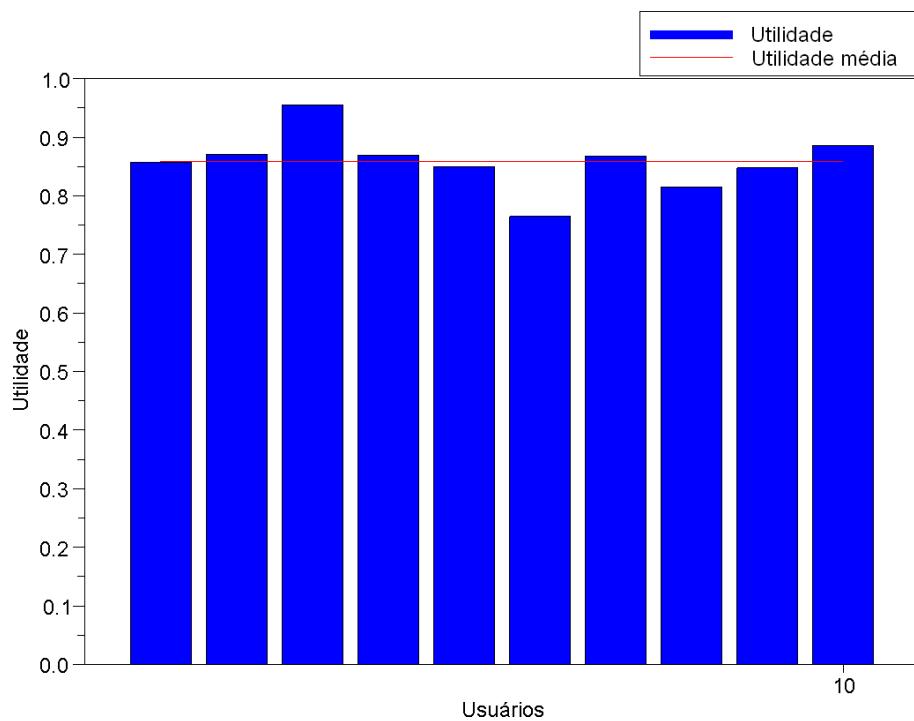


Figura 4.10: Utilidade típica para topologia local.

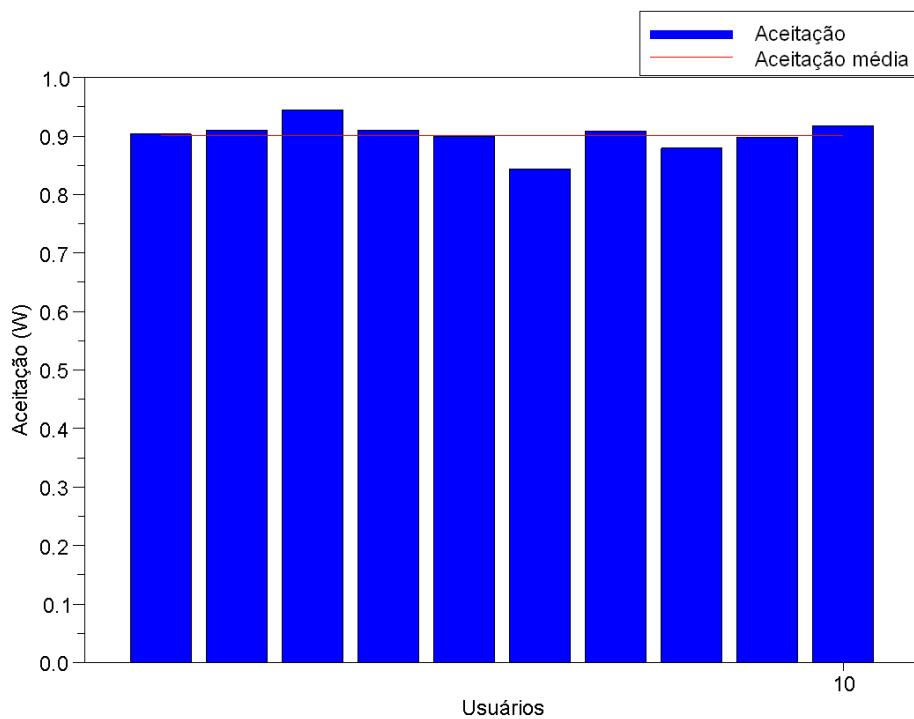


Figura 4.11: Aceitação típica para topologia local.

Capítulo 5

Conclusões

Esta monografia realizou um estudo sobre a aplicação de uma ferramenta metaheurística na resolução de problemas de gerência de recursos de rádio, que podem ser tratados como problemas de otimização.

Inicialmente um modelo econômico de alocação de recursos foi apresentado considerando-se aspectos de qualidade do serviço fornecido, tarifação e capacidade de geração de receita para a operadora. Foram abordados sistemas de comunicação móvel limitados por interferência, em que a capacidade de cada célula é determinada de forma dinâmica, de acordo com o padrão de utilização dos terminais.

Ao final do Capítulo 2 foi proposto um modelo de solução em que reduziu-se o número de variáveis independentes do problema fixando-se um valor para a SINR alvo dos terminais. A simplificação permitiu que a dimensão da solução fosse igual a uma unidade a mais que o número de usuários da célula.

No Capítulo 3 foi detalhado formalmente o problema de otimização com restrições e apresentado o conceito de otimização metaheurística. No mesmo capítulo foi descrito o algoritmo HPSO, proposto em He e Wang (2007) com a intenção de reunir as boas características das técnicas PSO e SA. Agregou-se ao método original alguns conceitos sugeridos em Bratton e Kennedy (2007) para PSO, como a possibilidade de alteração da topologia de enxame de partículas e a adição de um fator de constrição.

No Capítulo 4 apresentou-se os resultados de simulações do processo de otimização em vários cenários diferentes. A comparação de desempenho entre as versões com diferentes topologias revelou que, apesar da maior estabilidade e

melhores receitas médias obtidas pela topologia local, esta é muito mais lenta que a versão com topologia global. Entretanto, os gráficos da Seção 4.4.3 indicam que a alocação realizada pela versão local proporciona uma distribuição mais uniforme de recursos, melhorando os valores de utilidade e aceitação médias.

Foram realizadas ainda algumas considerações em relação às possibilidades de aumento da receita gerada para a operadora. Foi visto que o aumento de usuários por célula somente é interessante até certo ponto, determinado pela capacidade dinâmica do sistema. Além disso, viu-se que, apesar do modelo de tarifação influenciar na receita média obtida, é preciso analisar o cenário em que este será aplicado, procurando a alternativa mais viável. Outra opção citada que resulta em maior alocação de recursos e maior receita gerada envolve melhorias tecnológicas nos dispositivos transmissores e receptores, permitindo uma SINR alvo menor nos terminais.

O modelo de solução aplicado neste trabalho caracterizou-se pela reduzida quantidade de informação *a priori* e pela simplicidade das técnicas utilizadas, demonstrando a utilidade das metaheurísticas na otimização de problemas de engenharia.

5.1 Perspectivas para trabalhos futuros

Nesta monografia utilizou-se um algoritmo de otimização metaheurística para maximizar a receita média para a operadora. Dessa forma, não há critérios de justiça mais rigorosos em relação aos usuários. Uma oportunidade de trabalho seria investigar outras funções-objetivo que considerassem tais aspectos do serviço oferecido.

As técnicas estudadas se propõem a realizar a alocação de recursos de acordo com um determinado objetivo. Entretanto, quando a capacidade do sistema é excedida, o algoritmo não reserva quaisquer recursos para alguns terminais. Durante a operação de um sistema de comunicação esta situação pode ocorrer, sendo preciso gerenciar a ordem em que os usuários devem ser atendidos. Este passo envolve a adição de um controle de admissão prévio que selecione, de acordo com instruções específicas, a maneira como a fila de requisições será organizada. O projeto de tal sistema de controle pode ser alvo de estudo em trabalhos futuros.

Uma característica dos métodos baseados em PSO é sua natureza paralela, em

que cada partícula pode ser entendida como um agente explorador independente. Algumas técnicas aproveitam-se desse aspecto para aumentar a velocidade de execução do algoritmo, como as propostas em Schutte *et al.* (2004), Jin e Rahmat-Samii (2005) e Koh *et al.* (2006). Trabalhos futuros podem adicionar tais mecanismos de processamento paralelo ao método HPSO aplicado nesta monografia.

Referências Bibliográficas

- ANGHINOLFI, D.; PAOLUCCI, M. Simulated annealing as an intensification component in hybrid population-based metaheuristics. In: *Simulated Annealing*. Vienna, Austria: I-Tech Education and Publishing, 2008.
- BADIA, L. *et al.* An economic model for the radio resource management in multimedia wireless systems. *Computer Communications*, Amsterdam, Netherlands, v. 27, n. 11, p. 1056–1064, 2004.
- BADIA, L. *et al.* Demand and pricing effects on the radio resource allocation of multimedia communication systems. In: *Proceedings Globecom*. [S.l.: s.n.], 2003. v. 2003.
- BADIA, L. *et al.* An optimization framework for radio resource management based on utility vs. price tradeoff in WCDMA systems. In: IEEE COMPUTER SOCIETY. *Proceedings of the Third International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks*. [S.l.], 2005. p. 404–412.
- BADIA, L. *et al.* On the network utility optimal allocation of radio resources in WCDMA systems. *IEEE Communications Letters*, Institute of Electrical and Electronics Engineers, Piscataway, NJ, USA, v. 10, n. 5, p. 341–343, 2006.
- BADIA, L.; ZORZI, M. On utility-based radio resource management with and without service guarantees. In: *MSWiM '04: Proceedings of the 7th ACM international symposium on Modeling, analysis and simulation of wireless and mobile systems*. New York, NY, USA: ACM, 2004. p. 244–251.
- BARRICELLI, N. *et al.* Esempi numerici di processi di evoluzione. *Methodos*, v. 6, p. 21–22, 1954.

- BRATTON, D.; KENNEDY, J. Defining a standard for particle swarm optimization. In: *IEEE Swarm Intelligence Symposium*. Honolulu, Hawaii, USA: [s.n.], 2007. p. 120–127.
- CASE, K. E.; FAIR, R. C. *Principles of Microeconomics*. 7. ed. Amsterdam, Netherlands: Prentice Hall, 2003.
- CLERC, M.; KENNEDY, J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. In: *Evolutionary Computation, IEEE Transactions on*. [S.l.: s.n.], 2002. v. 6, n. 1, p. 58–73.
- DEB, K. An efficient constraint handling method for genetic algorithms. *Computer Methods in Applied Mechanics and Engineering*, Amsterdam, Netherlands, v. 186, n. 2-4, p. 311–338, 2000.
- DORIGO, M. *Optimization, learning and natural algorithms*. Tese (Doutorado) — Politecnico di Milano, Milão, Itália, 1992.
- EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: *Micro Machine and Human Science, 1995. MHS '95., Proceedings of the Sixth International Symposium on*. Piscataway, NJ, USA: [s.n.], 1995. p. 39–43.
- EBERHART, R. C.; SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. In: *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*. [S.l.: s.n.], 2000. v. 1, p. 84–88.
- ELAYOUBI, S.; CHAHED, T. Admission Control in the Downlink of WCDMA/UMTS. *Lecture Notes in Computer Science*, Springer, Citeseer, 2005.
- ELAYOUBI, S. et al. Optimization of radio resource management schemes in UMTS using pricing. *Computer Communications*, Elsevier, v. 28, n. 15, p. 1761–1769, 2005.
- FAMOLARI, D. et al. A new framework for power control in wireless data networks: Games, utility and pricing. In: SPRINGER. *Proceedings of the Annual Allerton Conference on Communication Control and Computing*. [S.l.], 1998. v. 36, p. 546–555.
- FOGEL, L. et al. *Artificial intelligence through simulated evolution*. [S.l.]: John Wiley & Sons Inc, 1966.

- GENTLE, J. *et al.* *Handbook of computational statistics*. Berlin, Alemanha: Springer Berlin, 2004.
- GLOVER, F. Future paths for integer programming and links to artificial intelligence. *Computers and Operations Research*, v. 13, n. 5, p. 533–549, 1986.
- HE, Q.; WANG, L. A hybrid particle swarm optimization with a feasibility-based rule for constrained optimization. *Applied Mathematics and Computation*, Amsterdam, Netherlands, v. 186, n. 2, p. 1407–1422, 2007.
- HOLDEN, N.; FREITAS, A. A. A hybrid pso/aco algorithm for discovering classification rules in data mining. *Journal of Artificial Evolution and Applications*, v. 2008, 2008. Disponível em: <<http://www.hindawi.com/journals/jaea/2008/316145.html>>.
- HOLLAND, J. Adaptation in natural and artificial systems. *Ann Arbor MI: University of Michigan Press*, 1975.
- ITU. *Number of cell phone subscribers to hit 4 billion this year, UN says*. 2008. Disponível em: <<http://www.un.org/apps/news/story.asp?NewsID=28251>>.
- JIN, N.; RAHMAT-SAMII, Y. Parallel particle swarm optimization and finite-difference time-domain (PSO/FDTD) algorithm for multiband and wide-band patch antenna designs. *Multi-Campus: Retirado de: http://www.escholarship.org/uc/item/1g21h4r8*, 2005.
- KELIF, J. *et al.* Admission and GoS control in a multiservice WCDMA system. *Computer Networks*, Elsevier, Amsterdam, Netherlands, v. 51, n. 3, p. 699–711, 2007.
- KENNEDY, J.; EBERHART, R. C. Particle swarm optimization. *Proceedings of the IEEE International Conference on Neural Networks*, Piscataway, NJ, USA, v. 4, p. 1942–1948, 1995.
- KIM, D. H. *et al.* Hybrid genetic: Particle swarm optimization algorithm. In: *Studies in Computational Intelligence*. Berlin, Germany: Springer Berlin / Heidelberg, 2007. p. 147–170.
- KIRKPATRICK, S. *et al.* Optimization by simulated annealing. *Science*, USA, v. 220, p. 671–680, 1983.

- KOH, B. *et al.* Parallel asynchronous particle swarm optimization. *International Journal for Numerical Methods in Engineering*, NIH Public Access, v. 67, n. 4, p. 578, 2006.
- LIU, B. *et al.* Improved particle swarm optimization combined with chaos. *Chaos, Solitons & Fractals*, Amsterdam, Netherlands, v. 25, n. 5, p. 1261–1271, 2005.
- LIU, H.; ABRAHAM, A. An hybrid fuzzy variable neighborhood particle swarm optimization algorithm for solving quadratic assignment problems. *Journal of Universal Computer Science*, v. 13, n. 9, p. 1309–1331, 2007. Disponível em: <http://www.jucs.org/jucs_13_9/an_hybrid_fuzzy_variable>.
- LØVBJERG, M. *Improving Particle Swarm Optimization by Hybridization of Stochastic Search Heuristics and Self-Organized Criticality*. Dissertação (Mestrado) — Aarhus Universitet, Datalogisk Institut, Denmark, 2002.
- NARAYAN, C. C. *et al.* Admission and flow control for multimedia cdma. In: *Proceedings of ICME 2000, IEEE Conference on Multimedia and Expo*. [S.l.: s.n.], 2000. p. 1265–1268.
- NETO, R. A. de O.; CAVALCANTI, F. R. P. Aspectos econômicos em gerenciamento de recursos de rádio. *XXV Simpósio Brasileiro de Telecomunicações - SBrT 2007*, 2007.
- PEDERSEN, K.; MOGENSEN, P. The downlink orthogonality factors influence on WCDMA system performance. In: IEEE. *IEEE Vehicular Technology Conference*. [S.l.], 2002. v. 4, p. 2061–2065.
- RECHENBERG, I. Cybernetic Solution Path of an Experimental Problem. *Royal Aircraft Establishment, Library Translation No. 1122*, Farnborough, UK, v. 1122, 1964.
- ROBBINS, H.; MONRO, S. A stochastic approximation method. *The Annals of Mathematical Statistics*, Institute of Mathematical Statistics, v. 22, n. 3, p. 400–407, 1951.
- SCHUTTE, J. *et al.* Parallel global optimization with the particle swarm algorithm. *International Journal for Numerical Methods in Engineering*, NIH Public Access, v. 61, n. 13, p. 2296, 2004.

- SPALL, J. C. *Introduction to Stochastic Search and Optimization*. New York, USA: Wiley, 2003.
- TALBI, E.-G. *Metaheuristics : from design to implementation*. [S.l.]: John Wiley & Sons, 2009.
- TELECO. *Banda Larga é o serviço de Telecom que mais cresce em 2009*. 2009. Disponível em: <<http://www.teleco.com.br/comentario/com330.asp>>.
- VARIAN, H. *Intermediate Microeconomics: A Modern Approach*. New York, NY, USA: Norton, 1999.
- XIAO, M. *et al.* A utility-based power-control scheme in wireless cellular systems. *IEEE/ACM Transactions on Networking (TON)*, IEEE Press Piscataway, NJ, USA, Piscataway, NJ, USA, v. 11, n. 2, p. 210–221, 2003.
- YAICHE, H. *et al.* A game theoretic framework for bandwidth allocation and pricing in broadband networks. *IEEE/ACM Transactions on Networking (TON)*, IEEE Press Piscataway, NJ, USA, v. 8, n. 5, p. 667–678, 2000.