



UNIVERSIDADE
ESTADUAL DE LONDRINA

MATEUS DE PAULA MARQUES

**ALOCAÇÃO DE RECURSOS EM REDES DE
COMUNICAÇÃO DE MÚLTIPLO ACESSO**

Londrina
2014

MATEUS DE PAULA MARQUES

**ALOCAÇÃO DE RECURSOS EM REDES DE
COMUNICAÇÃO DE MÚLTIPLO ACESSO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do Título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos Especialidade: Sistemas de Telecomunicações

Orientador: Prof. Dr. Taufik Abrão

Londrina
2014

**Catálogo elaborado pela Divisão de Processos Técnicos da Biblioteca Central da
Universidade Estadual de Londrina.**

Dados Internacionais de Catalogação-na-Publicação (CIP)

M357a Marques, Mateus de Paula.
Alocação de recursos em redes de comunicação de múltiplo acesso/
Mateus de Paula Marques. – Londrina, 2014.
101 f.: il.

Orientador: Taufik Abrão.
Dissertação (Mestrado em Engenharia Elétrica) - Universidade
Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de
Pós-Graduação em Engenharia Elétrica, 2014.

Inclui bibliografia
1. Acesso múltiplo por divisão de código – Teses. 2. Sistemas de
telecomunicação – Teses. 3. Engenharia elétrica – Teses. I. Abrão, Taufik.
II. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo.
Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 621 391

MATEUS DE PAULA MARQUES

**ALOCAÇÃO DE RECURSOS EM REDES DE COMUNICAÇÃO DE
MÚLTIPLO ACESSO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do Título de Mestre em Engenharia Elétrica.

BANCA EXAMINADORA

Orientador. Professor Dr. Taufik Abrão
Universidade Estadual de Londrina – UEL

Professor Dr. Fernando Ciriaco Dias Neto
Universidade Estadual de Londrina – UEL

Professor Dr. Paulo Laerte Natti
Universidade Estadual de Londrina – UEL

Londrina, 25 de maio de 2014

aos meus pais.

MARQUES, Mateus de Paula. **Alocação de recursos em redes de comunicação de múltiplo acesso**. 2014. 101 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Londrina, Londrina, 2014.

RESUMO

Neste trabalho, diferentes aspectos de alocação de recursos são tratados, tais como alocação de potência e taxa de informação, tendo em vista a otimização de operação dos sistemas de comunicação sem fio de múltiplo acesso DS/CDMA. A alocação de potência e de taxa de informação em sistemas DS/CDMA multi-taxa via múltiplos ganhos de processamento é abordada por meio de meta-heurísticas bioinspiradas. As metodologias de otimização por colônia de formigas em domínios contínuos (ACOR) e por enxame de partículas (PSO) foram aplicadas na resolução de três sub-problemas em redes de múltiplo acesso sem fio; tais sub-problemas são precisamente definidos pelo controle de potência da rede, a maximização ponderada do fluxo de informação e a maximização da eficiência energética da rede. A qualidade dos resultados obtidos foi analisada através da métrica erro quadrático médio normalizado (NMSE). Neste contexto, verificou-se que as meta-heurísticas empregadas foram capazes de garantir convergência na maior parte dos casos para soluções muito próximas do ótimo global ($NMSE \leq 10^{-3}$) quando seus parâmetros de entrada são devidamente calibrados. No que tange à complexidade computacional obtida com as meta-heurísticas, o ACOR atingiu em média 14, 3% da complexidade computacional requerida pelos algoritmos determinísticos utilizados, sendo 22% e 8, 91% no pior e no melhor caso, respectivamente. Já o PSO atingiu em média 30, 79%, sendo 71, 71% e 10, 2% no pior e no melhor caso, respectivamente. Assim, concluiu-se que as meta-heurísticas aqui abordadas, bem como os algoritmos propostos para a resolução de problemas de alocação de recursos em redes de comunicação de múltiplo acesso que utilizam procedimentos de otimização heurísticos, demonstram efetividade no projeto de redes sem fio com eficiência energética e espectral.

Palavras-chave: Acesso múltiplo por divisão de código. Sistemas de telecomunicação. Engenharia elétrica.

MARQUES, Mateus de Paula. **Resource allocation in communication networks multiple access**. 2014. 101 p. Dissertation (Master in Electrical Engineering) - University of Londrina, Londrina, 2014.

ABSTRACT

In this work, resource allocation was investigated in the power and rate allocation view, aiming to optimize the wireless multiple access system DS/CDMA. The power and rate allocation in multi-rate DS/CDMA with multiple processing gains is addressed via bio-inspired meta-heuristics. The ant colony optimization for continuous domains (ACOR) and the particle swarm optimization (PSO) algorithms were applied in the resolution of three resource allocation sub-problems in wireless multiple access networks; these sub-problems are precisely defined by the network power control, the weighted throughput maximization and the total energy efficiency maximization. The quality of the approximations analysis was given from the normalized mean squared error (NMSE) metric. In this context, the meta-heuristics were able to ensure convergence in almost all cases for solutions very close to the global optimum ($NMSE \leq 10^{-3}$) when its input parameters are properly calibrated. Regarding the achieved computational complexity, the ACOR algorithm reached an average of 14.3% of the computational complexity required by the deterministic algorithms, where 22% and 8.91% were achieved in the worst and best case, respectively. PSO, in turn, obtained an average of 30.79%, with 71.71% and 10.2% in the worst and best case, respectively. Thus, we concluded that the addressed meta-heuristics, as well as the proposed algorithms for resource allocation in wireless multiple access networks, demonstrate effectiveness for energetically and spectrally efficient wireless networks design.

Key words: Code division multiple access. Communication systems. Electric engineering.

Lista de Figuras

Figura 3.1:	Velocidade representada de maneira esquematizada em um plano Cartesiano	45
Figura 3.2:	Função a) Easom; b) Griewangk; c) Godstein & Price; d) Rosenbrock.....	50
Figura 3.3:	Evolução do MSE para as funções custo Sphere, Goldstein & Price, Griewank e Easom	51
Figura 3.4:	MSE e número de iterações em função dos valores atribuídos aos parâmetro q (a) no primeiro passo de calibragem, e ξ (b) no primeiro e (c) no segundo passo de calibragem. Função: Sphere	53
Figura 4.1:	Alocação de potência mínima (Eq. (2.23)) para $U = 5$ usuários.a) ACO_R [Marques et al. 2012]; b) PSO [Abrão et al. 2011].....	56
Figura 4.2:	NMSE para diferentes combinações dos parâmetros do ACOR com $U = 20$ usuários. Para todas as configurações, foi utilizado $L = 25, M_{ACO} = 35$	56
Figura 4.3:	NMSE alcançado pelos algoritmos RA-ACO e RA-PSO [Abrão ET al. 2011], para $U = 5, 10$ e 20 usuários.....	58
Figura 4.4:	Tempo de execução para os algoritmos RA-ACO e RA-PSO [Abrão et al. 2011], com $U = 5, 10$ e 20 usuários	60
Figura 4.5:	Evolução de ΣR e ΣP em função das iterações do ACO_R	62
Figura 4.6:	Taxas mínimas (QoS) e ótimas ($\text{Max } \Sigma R$) depois da convergência dos algoritmos ACO_R e CvX para o problema WTM com $U = 30$ usuários.....	64
Figura 4.7:	Níveis ótimos de potência ($\text{Max } \Sigma R$) depois da convergência dos algoritmos ACO_R e CvX para o problema WTM com $U = 30$ usuários.....	65
Figura 4.8:	Convergência dos níveis de potência individuais para o ACO_R a) e o PSO b) em um sistema com $U = 12$ usuários. Os níveis ótimos foram obtidos a partir do CvX.....	65
Figura 4.9:	Convergência das taxas de informações individuais para o ACO_R a) e o PSO b) em um sistema com $U = 12$ usuários. Os níveis ótimos foram obtidos a partir do CvX	66

Figura 4.10: Evolução do NMSE para o ACO _R em relação ao vetor de potências de transmissão \mathbf{p}^* para $U = [12; 20; 30]$ usuários	67
Figura 4.11: Comportamento da função custo para o vetor ótimo de potências de transmissão \mathbf{p}^* , exceto para as potências a) p_1 e b) p_{30} , em um sistema com $U = 30$ usuários	68
Figura 4.12: Tempo de execução dos algoritmos em função do número de usuários U para o problema WTM.....	69
Figura 4.13: Numero de operações de ponto flutuante para os algoritmos ACO _R e PSO	71
Figura 4.14: Otimização dos parâmetros de entrada do DM-ACO para $U = 12$ e $T = 1000$ execuções. NMSE e número de iterações no <i>loop</i> externo como funções dos valores dos parâmetros q , ξ e α . A variação dos parâmetros na primeira etapa da otimização: $q \in [0, 01; 0, 5]$, $\xi \in [0, 1; 1, 3]$, $\alpha \in [0, 1; 2, 0]$	73
Figura 4.15: Otimização dos parâmetros de entrada do DM-ACO para $U = 12$ e $T = 1000$ execuções. NMSE e número de iterações no <i>loop</i> externo como funções dos valores dos parâmetros q , ξ e α . A variação dos parâmetros na segunda etapa da otimização: $q \in [0, 4; 0, 5]$, $\xi \in [1, 25; 1, 35]$, $\alpha \in [0, 65; 0, 75]$	73
Figura 4.16: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada q em $T = 1000$ realizações	75
Figura 4.17: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada ξ em $T = 1000$ realizações	75
Figura 4.18: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada α em $T = 1000$ realizações.....	76
Figura 4.19: NMSE e número de iterações no <i>loop</i> externo (TDM-PSO) em função dos parâmetros de entrada ϕ_1 , ϕ_2 , ω e α para $U = 12$ usuários e $T = 1000$ realizações. Os parâmetros de entrada para o DM-PSO variam no intervalo ϕ_1 , $\phi_2 \in [0; 2]$, $\omega \in [0; 1]$, $\alpha \in [0; 2]$ no primeiro passo de otimização	77
Figura 4.20: NMSE e número de iterações no loop externo (NDM-PSO) em função dos parâmetros de entrada ϕ_1 , ϕ_2 , ω e α para $U = 12$ usuários e $T =$	

1000 realizações. Os parâmetros de entrada para o DM-PSO variam no intervalo: $\phi_1 \in [0, 2; 1, 4]$, $\phi_2 \in [0, 8; 1, 4]$, $\omega \in [0, 25; 0, 35]$, $\alpha \in [1; 2]$. no segundo passo de otimização.....	78
Figura 4.21: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ϕ_1	78
Figura 4.22: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ϕ_2	79
Figura 4.23: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ω	79
Figura 4.24: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada α	80
Figura 4.25: Comportamento da ΣEE para o vetor de potências ótimas \mathbf{p}^* , exceto para as potências a) p_1 e b) p_{30} . O número de iterações nos métodos DM: $T_{DM-CVX} = 6$; $T_{DM-ACO} = 6$ obtendo $\epsilon = 10^{-5}$, e $T_{DM-PSO} = 40$ obtendo $\epsilon = 10^{-3}$	82
Figura 4.26: Taxas de informação mínimas (QoS) e ótimas ($\max \Sigma EE$) obtidas depois de $T_{DM-CVX} = T_{DM-ACO} = 6$ e $T_{DM-PSO} = 40$ iterações.....	82
Figura 4.27: Evolução do NMSE para os algoritmos DM-ACO e DM-PSO com $U = [5; 12; 20; 30]$ usuários.....	84
Figura 4.28: Evolução da ΣEE para os algoritmos DM-ACO, DM-PSO and DMCVX em função das iterações no <i>loop</i> externo, considerando $U \in \{5; 12; 30\}$ usuários	85
Figura 4.29: Evolução da ΣP para os algoritmos DM-ACO, DM-PSO and DMCVX em função das iterações no loop externo, considerando $U \in \{5; 12; 30\}$ usuários	85
Figura 4.30: Evolução no <i>loop</i> interno do método DM (Algoritmo 1) para os algoritmos ACOR, CVX e PSO durante a primeira iteração; $U = 30$ usuários	86
Figura 4.31: Evolução das EE's individuais para os algoritmos a) DM-ACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários.....	87
Figura 4.32: Evolução das potências individuais para os algoritmos a) DMACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários.....	87

Figura 4.33: Evolução das taxas de informação individuais para os algoritmos a) DM-ACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários	88
Figura 4.34: Tempo de execução dos algoritmos DM-ACO, DM-CVX e DMPSO ao resolver o problema de maximização da eficiência energética total do sistema DS/CDMA no <i>downlink</i>	90
Figura 4.35: Operações de Ponto Flutuante para os algoritmos DM-ACO e DMCVX.....	91
Figura 4.36: Análise dos problemas MPA, WTM e EED a partir de ΣP , ΣR e ΣEE em função do número de usuários	93

Lista de Tabelas

Tabela 3.1: Funções de Benchmark utilizadas na Avaliação do ACO_R	49
Tabela 3.2: Resultados de Convergência para o ACO_R em $T = 10^3$	50
Tabela 4.1: Parâmetros do Sistema DS/CDMA Macro-Celular Multi-Taxa e de Canal	55
Tabela 4.2: Parâmetros de entrada sub-ótimos obtidos para o ACOR na resolução do problema da Eq. (2.23).....	57
Tabela 4.3: Parâmetros de entrada sub-ótimos obtidos em [Abrão et al. 2011] para o PSO na resolução do problema da Eq. (2.23)	58
Tabela 4.4: Robustez dos algoritmos RA-ACO e RA-PSO para o problema de controle de potência da Eq.(2.23) em 500 realizações	59
Tabela 4.5: Sistema DS/CDMA macro-celular multi-taxa, parâmetros de canal e do algoritmo ACO_R	61
Tabela 4.6: Nível médio de potência de transmissão obtido por classe de usuário	63
Tabela 4.7: Porcentagens obtidas para as métricas ΣP , ΣR e Tempo de Execução para os algoritmos ACO_R e PSO em relação ao algoritmo determinístico CvX.....	70
Tabela 4.8: Número de operações para os algoritmos ACO_R e PSO	70
Tabela 4.9: Parâmetros do Sistema DS/CDMA Macro-Celular Multi-Taxa e de Canal	72
Tabela 4.10: Parâmetros de entrada otimizados para os algoritmos DM- ACO_R e DM-PSO.....	81
Tabela 4.11: Resultados obtidos para as métricas de desempenho consideradas nas abordagens analítica (DM-CVX) e meta-heurística (DM-ACO, DM-PSO).....	83
Tabela 4.12: Porcentagem média de sucesso em $T = 1000$ realizações para os algoritmos DM-ACO e DM-PSO em relação ao DM-CVX após T_{DM} iterações, obtidas a partir da Fig. 4.28 para diferentes valores de ϵ_{min}	89
Tabela 4.13: Número de operações para os algoritmos DM-ACO e DM-PSO	90

Lista de Siglas

sigla	descrição
ACO	<i>Ant Colony Optimization</i> - Otimização por Colônia de Formigas
AWGN	<i>Additive White Gaussian Noise</i> - Ruído Aditivo Gaussiano Branco
BER	<i>Bit Error Rate</i> - Taxa de Erro de Bit
BS	<i>Base Station</i> - Estação Base
CDMA	<i>Code Division Multiple Access</i> - Múltiplo Acesso Por Divisão de Código
CNIR	<i>Carrier to Noise plus Interference Ratio</i> - Relação Portadora Interferência mais Ruído
DAB	<i>Digital Audio Broadcasting</i> - Difusão Digital de Áudio
DM	<i>Dinkelbach's Method</i> - Método de Dinkelbach
DPCA	<i>Distributed Power Control Algorithm</i> - Algoritmo Distribuído de Controle de Potência
DS/CDMA	<i>Direct Sequence CDMA</i> - CDMA por Sequência Direta
DVB	<i>Digital Video Broadcasting</i> - Difusão Digital de Vídeo
D-AMPS	<i>Digital Advanced Mobile Phone System</i> - Sistema de Telefonia Móvel Digital Avançada
EE	<i>Energy Efficiency</i> - Eficiência Energética
EGC	<i>Equal Gain Combining</i> - Combinação por Ganhos Iguais
ERB	Estação Rádio Base
GA	<i>Genetic Algorithm</i> - Algoritmo Genético
GLFP	<i>Generalized Linear Fractional Programming</i> - Programação Fracional Linear Generalizada
GSM	<i>Global System for Mobile Communications</i> - Sistema Global para Comunicações Móveis
HIPERLAN	<i>High Performance Radio LAN</i> - Rede Local via Radio de Alto Desempenho
IS-95	<i>Interim Standard 95</i> - Padrão Interino 95

continua...

sigla	descrição
IEEE	<i>Institute of Electrical and Electronics Engineers</i> - Instituto de Engenheiros Eletricistas e Eletrônicos
IMT-2000	<i>International Mobile Telecommunications 2000</i> - Telecomunicações Móveis Internacionais 2000
LAN	<i>Local Area Network</i> - Rede Local
LTE	<i>Long Term Evolution</i> - Evolução de Longo Prazo
LOS	<i>Line of Sight</i> - Linha de Visada
MC/CDMA	<i>Multi-Carrier CDMA</i> - CDMA Multi-Portadora
MLFP	<i>Multiplicative Linear Fractional Programming</i> - Programação Fracional Linear Multiplicativa
MMAC	<i>Mobile Multimedia Access Communication</i> - Comunicação Móvel de Múltiplo Acesso
MAI	<i>Multiple Access Interference</i> - Interferência de Múltiplo Acesso
MPA	<i>Minimum Power Allocation</i> - Alocação de Potência Mínima
MPG-DS/CDMA	<i>Multiple Processing Gains DS/CDMA</i> - DS/CDMA via Múltiplos Ganhos de Processamento
NMSE	<i>Normalized Mean Squared Error</i> - Erro Quadrático Médio Normalizado
NP	<i>Nondeterministic Polynomial Time</i> - Não Determinístico em Tempo Polinomial
OFDMA	<i>Orthogonal Frequency Division Multiple Access</i> - Múltiplo Acesso via Divisão Ortogonal de Frequências
OFDM	<i>Orthogonal Frequency Division Multiplexing</i> - Multiplexação por Divisão Ortogonal de Frequências
PDC	<i>Personal Digital Celular</i> - Celulares Digitais Pessoais
PDF	<i>Probability Density Function</i> - Função Densidade de Probabilidade
PMF	<i>Probability Mass Function</i> - Função Massa de Probabilidade
PSO	<i>Particle Swarm Optimization</i> - Otimização por Enxame de Partículas
QoS	<i>Quality of Service</i> - Qualidade de Serviço

continua...

sigla	descrição
QAM	<i>Quadrature Amplitude Modulation</i> - Modulação por Amplitude em Quadratura
QPSK	<i>Quadrature Phase Shift Keying</i> - Modulação por Deslocamento de Fase
RA-ACO	<i>Resource Allocation via Ant Colony Optimization</i> - Alocação de Recursos via ACO
RA-PSO	<i>Resource Allocation via Particle Swarm Optimization</i> - Alocação de Recursos via PSO
CVX	<i>Matlab Software for Disciplined Convex Programming</i> - Software em Matlab para Programação Convexa Disciplinada
RF	Radio Frequência
SNIR	<i>Signal to Noise plus Interference Ratio</i> - Relação Sinal Ruído mais Interferência
SE	<i>Spectral Efficiency</i> - Eficiência Espectral
SERV	Classes de Serviço
UMTS	<i>Universal Mobile Telecommunications System</i> - Sistema Universal de Telecomunicações Móveis
WiMAX	<i>Worldwide Interoperability for Microwave Access</i> - Interoperabilidade Mundial para Acesso via Microondas
WTM	<i>Weighted Throughput Maximization</i> - Maximização Ponderada de Fluxo

Convenções e Lista de Símbolos

Os seguintes símbolos são utilizados:

símbolo	descrição
i	Indexador de dimensões (Usuários)
γ	SNIR
r_c	Taxa de <i>chip</i>
r	Taxa de informação
Γ	CNIR
U	Número de dimensões do problema (Usuários)
p	Potência de transmissão
g	Ganho de canal
σ	Desvio padrão de uma dada PDF
p_{\max}	Potência máxima de transmissão
\mathbf{G}	Matriz de ganhos de canal
\mathcal{L}	Perda de percurso
β	Expoente da perda de percurso
\mathcal{S}	Sombreamento
\mathcal{N}	PDF Gaussiana
\mathcal{A}	Desvanecimento multi-percurso
F	Ganho de Processamento
W	Largura de banda do sistema
θ	<i>Gap</i> entre as taxas de informação teórica e real
M	Ordem de modulação
w	Largura de banda do sinal antes do espalhamento (Ou da sub-portadora)
BER^{\max}	BER máxima tolerável
\mathcal{V}	Fluxo de informação total do sistema
\mathbf{B}	Matriz de interferência normalizada
\mathbf{u}	Vetor de ruído normalizado
\mathbb{F}^{th}	Função de <i>threshold</i>
η_E	Eficiência Energética

continua...

símbolo	descrição
P_t	Potência de transmissão total
P_c	Potência de circuitaria
ι	Ineficiência do amplificador RF
\mathcal{Q}	Programa fracional côncavo
\mathcal{Q}_p	Programa paramétrico côncavo
t	indexador de iterações
ϵ	tolerância (condição de parada de algoritmos)
L	tamanho do arquivo de soluções do $\text{ACO}_{\mathbb{R}}$
l	indexador de soluções no arquivo
ρ	Vetor de pesos (PDF de núcleo Gaussiano)
μ	Vetor de médias (PDF de núcleo Gaussiano)
M_{ACO}	População do $\text{ACO}_{\mathbb{R}}$
M_{PSO}	População do PSO
\mathcal{G}	PDF de núcleo Gaussiano
\mathbf{J}	Vetor de soluções do arquivo do $\text{ACO}_{\mathbb{R}}$ aplicado à função custo
\mathcal{R}	Robustez
cS	Sucesso de convergência
\mathcal{T}	Número de realizações
T	Número máximo de iterações
$P(l)$	Probabilidade de escolha da l -ésima solução
ξ	Taxa de evaporação de feromônio
q	Fator de diversidade ($\text{ACO}_{\mathbb{R}}$)
α	Coefficiente de volatilidade
ω	Peso da Inércia (PSO)
ϕ_1	Coefficiente de Aceleração Local (PSO)
ϕ_2	Coefficiente de Aceleração Global (PSO)
T_s	Período de símbolo

Sumário

1	Introdução	18
1.1	Organização	22
1.2	Publicações Associadas	22
2	Alocação de Recursos em Redes de Múltiplo Acesso	24
2.1	Definições e Modelo do Sistema DS/CDMA	25
2.1.1	Desvanecimentos de pequena e de larga escala	26
2.1.2	Capacidade do canal sem fio e requisitos de QoS	28
2.2	Estratégias de Controle de Potência em Redes CDMA	30
2.2.1	O Problema de Alocação de Potência Mínima	30
2.2.2	O Problema da Maximização da Vazão (WTM)	32
2.2.3	O Problema da Maximização da Eficiência Energética	35
3	Meta-Heurísticas Bio-Inspiradas	39
3.1	O ACO _R	39
3.2	O Algoritmo PSO Contínuo	45
3.3	Meta-Heurísticas aplicadas ao método de Dinkelbach: DM-ACO e DM-PSO	47
3.4	Benchmark ACO _R	48
3.4.1	Robustez versus Velocidade de Convergência	51
4	Resultados Numéricos para Alocação de Recursos em Redes de Múltiplo Acesso	54
4.1	Alocação de Potência Mínima em Redes MPG-DS/CDMA	55
4.1.1	Desempenho do ACO _R X PSO	57
4.1.2	Complexidade Computacional	59
4.2	Maximização do Fluxo de Informação do Sistema (WTM)	60
4.2.1	Complexidade Computacional	67
4.3	Maximização da Eficiência Energética	71
4.3.1	Calibragem de Parâmetros para o DM-ACO	72

4.3.2	Calibragem de Parâmetros para o DM-PSO	76
4.3.3	Maximização da Eficiência Energética.....	80
4.3.4	Análise de Complexidade Computacional.....	88
4.4	MPA, WTM e EED	92
5	Conclusões	94
	Referências	96
	Apêndice A – Prova da quase-concavidade da equação 2.30.....	100

1 Introdução

A crescente demanda de serviços de comunicação fomentou a rápida evolução das redes sem fio nas últimas décadas. O rápido aumento do número de usuários na telefonia móvel, que hoje ultrapassa a marca de um bilhão [ElNashar, El-saidny e Sherif 2014], deixa clara a importância das redes sem fio neste novo século. Em paralelo, a chegada da era da informação gerou novos tipos de serviços com diferentes exigências de taxa de informação. Além disso, a evolução nas redes sem fio não aconteceu apenas nos sistemas de telefonia móvel (GSM, IS-95, D-AMPS, PDC, UMTS ou CDMA-2000), mas também nas redes locais sem fio (HIPERLAN/2, IEEE 802.11a/b/g/n, Bluetooth, Zigbee, etc), e redes de grande difusão (WiMAX, DAB, DVB, etc).

Tais tendências vêm aumentando desde o começo dos anos 90, na chegada da segunda geração (2G) dos sistemas de telefonia móvel (GSM, IS-95, D-AMPS e PDC) que possibilitaram o uso de redes digitais. Em seguida, a chegada dos sistemas de terceira geração (3G) (UMTS, IMT-2000 e CDMA-2000) permitiu a utilização de novos serviços, devido à maiores taxas de informação atingíveis (Taxa atingível de 2Mbit/s, contra 64kbit/s atingíveis nos sistemas 2G) [Fazel e Kaiser 2003]. Atualmente, inúmeras pesquisas vem sendo realizadas visando a quarta geração de sistemas de telefonia celular (i.e. LTE), bem como para gerações futuras.

As evoluções alcançadas nas redes sem fio são dadas pela aplicação de novas tecnologias que melhoram a utilização de recursos escassos como espectro e energia. Novas técnicas de alocação de recursos, detecção multi-usuário, modulação, etc, viabilizaram a utilização de serviços com altos requisitos de taxa de informação (vídeo-conferências, jogos online em tempo real, etc) em terminais móveis. Isso fez com que as redes sem fio ficassem entre as mais importantes áreas no ramo das comunicações atualmente.

Existem dois aspectos fundamentais nas redes sem fio, que fazem sua aplicação ser muito mais desafiadora em relação às redes cabeadas. Primeiramente, o fenômeno de desvanecimento: as variações na qualidade do sinal devido ao

desvanecimento de multi percurso, à perda de percurso devido à distância, e ao sombreamento por obstáculos. Além disso, a comunicação em redes sem fio está sujeita a grandes níveis de interferência de múltiplo acesso (MAI), o que geralmente não acontece em redes cabeadas. Desta forma, a maneira na qual se deve lidar com o desvanecimento e a interferência é de suma importância para o desenvolvimento de redes sem fio.

Neste trabalho, uma abordagem meta-heurística foi desenvolvida para problemas de alocação de recursos em redes sem fio de múltiplo acesso por divisão de código. A alocação otimizada de recursos em redes sem fio, especialmente a alocação de potência e taxa, é um problema de grande interesse tanto para as empresas de telecomunicações quanto para os usuários. Sabe-se que espectro e energia são recursos valiosos devido à sua escassez, uma vez que o primeiro é um recurso natural limitado e extremamente caro, e o último é limitado pela bateria e pelo tamanho do dispositivo. Portanto, é muito importante propor novas técnicas e algoritmos capazes de alocar esses recursos de forma simples e otimizada.

Nas últimas décadas, muitos pesquisadores têm trabalhado neste contexto buscando algoritmos simples e robustos para a alocação de recursos em sistemas sem fio. Em [Foschini e Miljanic 1993], um algoritmo distribuído para controle de potência (DPCA) foi proposto, e é considerado um dos trabalhos mais relevantes no âmbito da alocação de recursos até hoje. Devido à baixa capacidade de processamento dos terminais móveis, uma grande preocupação no âmbito da alocação de recursos tem sido a utilização de algoritmos de baixa complexidade computacional, a fim de reduzir a quantidade de energia gasta no processo de otimização. Neste cenário, as técnicas de otimização por meta-heurísticas bio-inspiradas vem sendo amplamente aplicadas na resolução de problemas como o controle de potência e taxa, devido à sua baixa complexidade computacional em relação aos métodos determinísticos de otimização, ao custo de resultados sub-ótimos. Uma abordagem meta-heurística baseada no algoritmo genético (GA) foi desenvolvida em [Moustafa, Habib e Naghshineh 2001], apresentando o controle conjunto de potência e taxa em uma rede CDMA. Em [Elkamchouchi, Elragal e Makar 2007], o algoritmo meta-heurístico de otimização por enxame de partículas (PSO) foi utilizado para desenvolver um algoritmo de controle de potência com baixa complexidade. Finalmente, [Zielinski et al. 2009] propôs uma abordagem de alocação de potência para resolver o cancelamento paralelo de interferências em detectores multiusuário.

Recentemente, métodos para alocação de recursos visando eficiência energética, em sua maioria aplicáveis a sistemas de múltiplo acesso por divisão ortogonal

de frequências (OFDMA) têm sido propostos recentemente [Mella et al. 2012, Ahmadi e Chew 2010, Ahmadi, Chew e Chai 2011]. Em [Mella et al. 2012], dois algoritmos baseados no algoritmo meta-heurístico de otimização por colônia de formigas (ACO) [Dorigo e Caro 1999] foram propostos para a alocação de recursos em um sistema OFDM. O ACO também foi aplicado para resolver a alocação de bits e sub-portadoras em um sistema OFDMA unicelular em [Ahmadi e Chew 2010], sendo o problema de otimização modelado a partir de multi-grafos, com os vértices representando as sub-portadoras e as arestas correspondendo às possíveis ordens de modulação associadas a cada usuário. Tal abordagem de alocação de recursos é capaz de garantir os requisitos de qualidade de serviço (QoS) com relação à taxa de informação mínima e taxa de erro de bit (BER) máxima tolerável para todos os usuários, e ao mesmo tempo, possibilita a redução do consumo total de potência na estação rádio base (ERB). Uma abordagem centralizada para a alocação de recursos em um sistema OFDMA multiusuário e multi-celular é apresentada em [Ahmadi, Chew e Chai 2011]. O ACO auxiliado pela técnica water-filling [Palomar e Fonollosa 2005] é aplicado na resolução do problema de alocação de potência centralizado. A visibilidade e a intensidade do rastro das formigas são parâmetros definidos pelo ACO, e neste caso, a visibilidade é utilizada para selecionar os recursos sub-portadoras e potência de transmissão, aumentando o número total de bits transmitidos na célula, enquanto a intensidade do rastro define soluções que diminuem a interferência intercelular.

Além das abordagens via meta-heurísticas, abordagens analíticas também foram propostas no âmbito da alocação de recursos em redes de múltiplo acesso. Em geral, abordagens analíticas possuem maior complexidade computacional em relação às meta-heurísticas, porém, são capazes de garantir a otimalidade das soluções. Em [Lee, Mazumdar e Shroff 2005], um algoritmo baseado na atribuição dinâmica de custos para a alocação de potência em um sistema CDMA foi proposto. Posteriormente, o modelo populacional de Verhulst, primeiramente desenvolvido para descrever o crescimento de espécies biológicas em ambientes com restrição de espaço e comida, foi adaptado em [Gross, Abrão e Jeszensky 2006] para o controle de potência distribuído em uma rede DS/CDMA. Vale ressaltar que este trabalho foi o primeiro a propor uma adaptação do modelo populacional de Verhulst para problemas de alocação de potência em redes de múltiplo acesso.

Nas redes sem-fio de múltiplo acesso, onde a única fonte de energia disponível para os terminais é a bateria, existe um compromisso entre uma transmissão livre de erros, e a redução no consumo de energia disponível na bateria, o que impacta na máxima taxa de informação alcançável. Uma medida natural de desempenho

que quantifica este compromisso é a eficiência energética do terminal móvel, definida pela razão entre a taxa de informação atingida e as potências de transmissão e de circuitaria utilizadas, sendo medida em bits por Joule. Em [Saraydar, Mandayam e Goodman 2002], um algoritmo distribuído para alocação de potência é proposto, onde cada usuário tenta maximizar a qualidade do seu serviço (QoS) através de um jogo não cooperativo [Myerson 1997]. A saída do jogo resulta em um equilíbrio de Nash que é ineficiente, e assim, é introduzida uma função penalidade linear nas potências de transmissão. A teoria de jogos [Myerson 1997] também foi utilizada em [Zappone, Buzzi e Jorswieck 2011] a fim de maximizar a eficiência energética de uma rede DS/CDMA sem fio auxiliada por repetidores do tipo amplifica e transmite. Já em [Zhang et al. 2013], um algoritmo de baixa complexidade computacional formulado a partir de um jogo não cooperativo foi proposto para um sistema OFDMA no *downlink* com *femtocells*¹ densas.

Finalmente, uma abordagem analítica para o problema de maximização ponderada de taxa de informação (*Weighted Throughput Maximization* - WTM), denominada MAPEL, foi proposto em [Qian, Zhang e Huang 2008]. O algoritmo realiza o controle de potência em uma rede sem fio limitada por interferência (CDMA e MC/CDMA), através de uma função custo monotonicamente crescente. Esta função foi formulada como um problema de programação linear fracional multiplicativa (*Multiplicative Linear Fractional Programming* - MLFP), que por sua vez, é um caso especial de programação linear fracional generalizada (*Generalized Linear Fractional Programming* - GLFP) [Schaible e Ibaraki 1983, Hoai-Phuong e Tuy 2003, Crouzeix e Ferland 1991]. Com isso, o problema GLFP apresentado em [Qian, Zhang e Huang 2008] foi utilizado em [Sampaio et al. 2010, Marques et al. 2012], a fim de formular uma função custo não decrescente a partir do produtório ponderado de SNIRs.

Neste trabalho, os problemas de controle de potência visando o aumento da capacidade do sistema de comunicação de múltiplo acesso por divisão de código (DS/CDMA), em termos de número de usuários, maximização da taxa de informação, bem como redução no consumo total de energia (maximização eficiência energética) foram estudados através de uma abordagem heurística utilizando o algoritmo ACO. Os resultados numéricos obtidos (Capítulo 4) comprovaram a capacidade do ACO em resolver problemas de alocação de recursos tanto de natureza convexa (Maximização das Eficiências Energética e Espectral) como não-convexa (Controle de Potência), ambos sob custos aceitáveis de complexidade

¹Em telecomunicações, uma femtocell é uma estação rádio base pequena e de baixo consumo de energia, tipicamente utilizada em ambientes fechados (*indoor*).

computacional.

1.1 Organização

Este trabalho de Dissertação foi elaborado como segue. No capítulo 2, a formulação dos problemas de alocação de recursos em redes de múltiplo acesso por divisão de código (DS/CDMA) é apresentada. As meta-heurísticas utilizadas na resolução dos problemas de otimização são apresentadas no capítulo 3. No capítulo 4 são discutidos os resultados numéricos obtidos para os três sub-problemas de otimização em redes de múltiplo acesso CDMA. Finalmente, no capítulo 5 são apresentadas as conclusões obtidas no desenvolvimento este trabalho.

1.2 Publicações Associadas

Os textos científicos/tecnológicos gerados até o momento como resultado do trabalho de investigação desta Dissertação são sintetizados seguir:

Trabalhos aceitos para publicação ou publicados:

- [1] Marques, Mateus de Paula; Sampaio, L. D. H.; C. Adaniya, Mario H. A.; Abrão, Taufik; E. Jeszensky, Paul Jean. *Ant Colony Optimization for Resource Allocation and Anomaly Detection in Communication Networks*. Publicado em: **Search Algorithms for Engineering Optimization**. Editor: Taufik Abrão. 1ed.Rijeka: InTech, 2013, v. 1, p. 134.
- [2] Marques, Mateus de Paula; Sampaio, L. D. H.; Ciriaco, Fernando; Durand, F. R.; Abrão, Taufik. *Energy Efficiency Optimization in MPG DS/CDMA*. Publicado no **XXXI Simpósio Brasileiro de Telecomunicações**, 2013, Fortaleza.
- [3] Marques, Mateus de Paula; Angélico, Bruno A.; Abrão, Taufik. Otimização Heurística por Colônia de formigas com Aplicações em Sistemas de Comunicações. Aceito para publicação na revista **Semina: Ciências Exatas e Tecnológicas** em 07/03/2014.

Trabalhos Submetidos:

- [4] Marques, Mateus de Paula; Sampaio, L. D. H.; Durand, Fabio Renan; Abrão, Taufik. *Resource Allocation under Energy-Efficient Design for Mul-*

trate Multiple Access Networks via Ant Colony Optimization. Submetido à revista **IET Communications** em 13/12/2013.

- [5] Marques, Mateus de Paula; Durand, Fabio Renan; Abrão, Taufik. *Energy-Efficient Resource Allocation for OCDM/WDM Networks via Ant Colony Optimization*. Em processo de submissão.
- [6] Marques, Mateus de Paula; Ciriaco, Fernando; Abrão, Taufik. *Power-Rate Control in Multirate Multiple Access Networks via Heuristic Ant Colony Optimization*. Em processo de submissão.

2 Alocação de Recursos em Redes de Múltiplo Acesso

Em redes CDMA, todos os usuários ativos compartilham o mesmo espectro (mesma faixa de frequência) ao mesmo tempo para a transmissão e recepção dos sinais, diferentemente de outros métodos de acesso, como por exemplo, o FDMA (*Frequency Division Multiple Access*) e o TDMA (*Time Division Multiple Access*), os quais utilizam diferentes frequências ou intervalos de tempo (*time-slots*), respectivamente, para alocarem os sinais dos usuários ativos.

Desta forma, o CDMA utiliza uma técnica de múltiplo acesso baseada em espalhamento espectral, que pode ser implementada de três formas: por sequência direta (*Direct Sequence CDMA*, DS/CDMA), por salto de frequência (*Frequency Hopping FH/CDMA*) ou por salto de tempo (*Time Hopping TH/CDMA*). Portanto, a unicidade de cada tipo de sequência de espalhamento (espectral) torna possível a separação dos sinais de seus respectivos interferentes [Oliveira et al. 2006].

Neste tipo de sistema de comunicação, a transmissão no mesmo espectro ao mesmo tempo gera a interferência de múltiplo acesso (MAI), intrínseca a sistemas de múltiplo acesso, e proporcional à correlação cruzada entre os sinais. Os diferentes níveis de interferência são gerados pelo número de usuários interferentes e pelas características do conjunto de sequências de espalhamento escolhido. Desta forma, a MAI torna-se o fator limitante dos sistemas CDMA.

As redes CDMA revolucionaram o sistema de telefonia móvel quando possibilitaram a conexão de celulares por canais de banda larga, além de permitir um melhor aproveitamento do espectro, comparado às redes do Sistema Móvel Global (GSM) [Al-Hezmi et al. 2007]. Esta flexibilidade no aproveitamento do espectro fomentou o desenvolvimento de várias técnicas de alocação de recursos.

Atualmente, devido à escassez de espectro, às restrições de energia dos aparelhos e à crescente necessidade de garantia de qualidade de serviço (QoS), várias pesquisas vem sendo feitas em busca de soluções, ponderando entre garantia de

QoS e máxima vazão do sistema, ambos conflitantes e diretamente dependentes da alocação de potência e taxa de informação. Desta forma, este trabalho objetiva estudar a alocação de recursos em redes de múltiplo acesso CDMA através de meta-heurísticas bio-inspiradas (*Particle Swarm Optimization* - PSO, *Ant Colony Optimization* - ACO). A seguir, os problemas de alocação de recursos em sistemas DS-CDMA abordados, bem como os seus princípios topológicos e de acesso serão apresentados.

2.1 Definições e Modelo do Sistema DS/CDMA

Nas redes DS/CDMA, a taxa de erro de bit (BER) é comumente utilizada como uma métrica QoS, uma vez que está diretamente associada à relação sinal ruído mais interferência (SNIR). Portanto, a SNIR está associada à relação portadora ruído mais interferência (CNIR) como:

$$\gamma_i = \frac{r_c}{r_i} \Gamma_i, \quad i = 1, \dots, U \quad (2.1)$$

sendo γ_i é a SNIR do i -ésimo usuário, r_c é a taxa de chip, r_i a taxa de informação do i -ésimo usuário, U é o número de usuários no sistema e Γ_i a CNIR do i -ésimo usuário, definida como segue [Gross, Abrão e Jeszensky 2006]:

$$\Gamma_i = \frac{p_i |g_{ii}|^2}{\sum_{j=1, i \neq j}^U p_j |g_{ij}|^2 + \sigma^2}, \quad i = 1, \dots, U \quad (2.2)$$

sendo p_i a potência de transmissão do i -ésimo usuário limitada em p_{\max} , $|g_{ii}|$ a amplitude do ganho de canal do i -ésimo usuário, $|g_{ij}|$ a amplitude do ganho de canal dos sinais interferentes e σ^2 a potência do ruído aditivo gaussiano branco (*Additive White Gaussian Noise* - AWGN) na entrada do i -ésimo receptor. Desta forma, a matriz de ganhos de canal $\mathbf{G}_{\text{upl}}^{U \times U}$ para um sistema empregando a tecnologia DS/CDMA no *uplink*, cujos sinais estão submetidos aos efeitos de perda de percurso, sombreamento e desvanecimento multi-percurso, pode ser representada por [Sampaio et al. 2010]:

$$\mathbf{G}_{\text{upl}} = \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1U} \\ g_{21} & g_{22} & \dots & g_{2U} \\ \vdots & \vdots & \ddots & \vdots \\ g_{U1} & g_{U2} & \dots & g_{UU} \end{bmatrix} \quad (2.3)$$

sendo a diagonal principal (g_{ii}) apresenta o vetor de ganhos de canal, enquanto os outros valores representam os ganhos dos sinais interferentes, sendo i o indexador de usuários. No *downlink*, por sua vez, a matriz de ganhos de canal $G_{\text{downl}}^{B \times U}$ é dada por:

$$\mathbf{G}_{\text{downl}} = \begin{bmatrix} g_{11} & g_{12} & \cdots & g_{1U} \\ g_{21} & g_{22} & \cdots & g_{2U} \\ \vdots & \vdots & \ddots & \vdots \\ g_{B1} & g_{B2} & \cdots & g_{BU} \end{bmatrix} \quad (2.4)$$

onde B é o número de estações rádio-base (ERBs) do sistema.

2.1.1 Desvanecimentos de pequena e de larga escala

Nesta seção, os desvanecimentos de pequena e larga escala serão analisados, a fim de representar matematicamente as amplitudes dos ganhos de canal, bem como de compreender os efeitos sofridos por qualquer sinal transmitido pelo meio sem fio. Tais efeitos são divididos entre duas categorias [Tse e Viswanath 2005]:

- *Desvanecimento de larga escala:* Ocorre devido à perda de percurso dos sinais em função da distância, e ao sombreamento provocado por objetos de dimensões muito maiores que o comprimento de onda, como construções e montanhas. Os desvanecimentos de larga escala ocorrem quando o móvel se desloca à distâncias da ordem do tamanho da célula, e normalmente não dependem da frequência do sinal transmitido.
- *Desvanecimento de pequena escala:* Ocorre devido às interferências construtivas e destrutivas das várias cópias do sinal, que com percursos diferentes entre o transmissor e o receptor, acontecem em escalas da ordem do comprimento de onda, e com isso são geralmente dependentes da frequência.

Ambos os tipos de desvanecimento são bastante destrutivos à qualidade do sinal, e por isso serão abordados no decorrer desta seção. Apesar disso, no que tange o projeto de sistemas de telefonia móvel, os desvanecimentos de pequena escala são os verdadeiros responsáveis pelos trabalhos realizados na literatura até hoje, uma vez que não é possível esquivar-se deles apenas limitando o tamanho das células. As bruscas mudanças na qualidade do sinal devido ao efeito *doppler* e ao desvanecimento por multi-percurso têm fomentado várias pesquisas na área de detecção de sinais e estimativa de canais sem fio. Na perspectiva da alocação de recursos, esses efeitos devem ser considerados a fim de garantir a chegada de sinais passíveis de detecção no receptor.

Definição 2.1.1. *A perda de percurso (\mathcal{L}) é dada pela perda de energia em função da distância percorrida por um sinal no meio sem fio, e pode ser definida como [Tse e Viswanath 2005]:*

$$\mathcal{L} = d^{-\beta} \quad (2.5)$$

onde d é a distância em relação à antena transmissora, e β o fator de atenuação. Para ambientes abertos, $\beta = 2$ é considerado, o que é razoável se considerarmos esferas concêntricas de raio d centralizadas na antena, uma vez que a potência total irradiada ao longo da esfera é constante, mas a área da superfície de cada esfera aumenta na ordem de d^2 . Portanto, a densidade de potência por área de superfície diminui em d^{-2} . Apesar disso, em situações reais, a perda de percurso pode provocar efeitos muito além de $\beta = 2$, dadas obstruções intrínsecas de meios fortemente verticalizados, como por exemplo os grandes centros urbanos.

Em ambientes verticalizados, os objetos podem refletir, refratar e difratar o sinal transmitido. O efeito de reflexão, gera o desvanecimento em multi-percurso, já os efeitos de refração e difração, geram o efeito de sombreamento.

Definição 2.1.2. *O sombreamento é ocasionado por objetos localizados no percurso do sinal, que geram alterações no nível de energia que chega no receptor. Além disso, este efeito é considerado como sendo de larga escala, uma vez que ele pode ocorrer de forma aproximadamente constante por vários segundos, podendo chegar a minutos. Desta forma, o sombreamento pode ser definido como [Tse e Viswanath 2005]:*

$$\mathcal{S} = \ln \mathcal{N}(0, \sigma^2) \quad (2.6)$$

ou seja, o sombreamento médio no sistema pode ser modelado a partir de uma distribuição log-normal, de média zero e variância igual à potência média do AWGN.

Definição 2.1.3. *O desvanecimento por multi-percurso é dado pela reflexão do sinal em objetos que se encontram em seu caminho. Ademais, este efeito é caracterizado como sendo de pequena escala, dada sua variação em milésimos de segundo. Em ocasiões em que não ocorre linha de visada (LOS) entre o transmissor e o receptor, este efeito pode ser modelado através da distribuição aleatória de Rayleigh. Já quando há a linha de visada, o desvanecimento em multi-percurso deve ser modelado pela distribuição de Rice [Stuber 1996]:*

$$\mathcal{A} = \begin{cases} \sum_{l=1}^L |(\sqrt{2})^{-1} [\mathcal{N}_l(0, \sigma^2) + j\mathcal{N}_l(0, \sigma^2)]| & \text{Rayleigh} \\ \sum_{l=1}^L |(\sqrt{2})^{-1} [\mathcal{N}_l(\nu \cos \theta, \sigma^2) + j\mathcal{N}_l(\nu \cos \theta, \sigma^2)]| & \text{Rice} \end{cases} \quad (2.7)$$

onde $j = \sqrt{-1}$ e l os diferentes percursos do sinal. Vale ressaltar que em ambos os casos (com ou sem LOS), a equação (2.7) considera a combinação por ganhos iguais dos diferentes percursos no receptor (EGC). Finalmente, a combinação desses efeitos é dada [Tse e Viswanath 2005]:

$$g_{ii} = \mathcal{L}_i \mathcal{S}_i \mathcal{A}_i \quad (2.8)$$

2.1.2 Capacidade do canal sem fio e requisitos de QoS

Nas redes DS/CDMA onde os usuários podem fazer uso de vários tipos de serviço através de múltiplos ganhos de processamento (MPG), é definido o ganho de processamento $F_i > 1$ como uma função da taxa de chip:

$$F_i = \frac{r_c}{r_i}, \quad i = 1, 2, \dots, U \quad (2.9)$$

Portanto, a partir das equações (2.1) e (2.9) obtém-se:

$$\gamma_i = F_i \Gamma_i \quad (2.10)$$

A capacidade teórica de um canal AWGN sem fio de múltiplo acesso, com banda W e SNIR γ é dada por [Shannon 1948, Tse e Viswanath 2005]:

$$C = W \log_2(1 + \gamma) \quad (2.11)$$

Uma vez que a equação (2.11) é um limite teórico e considera sistemas que não empregam a tecnologia CDMA, especificamente, o espalhamento espectral, faz-se necessária a inclusão de um *gap* entre o limite teórico e real, além de considerar a largura de banda do sinal a ser transmitido antes do espalhamento, ou seja:

$$r_i = \frac{w_i}{m_i} \log_2(1 + \theta_i \gamma_i) \quad \left[\frac{\text{bits}}{\text{seg}} \right] \quad (2.12)$$

onde r_i é a taxa de informação atingível para o i -ésimo usuário, $m_i = \log_2 M_i$

é a ordem de modulação, θ_i o inverso do *gap* entre o limite teórico e a taxa de informação real alcançável, $w_i = \frac{W}{F_i}$ é a largura de banda do sinal do i -ésimo usuário medida antes do espalhamento, e $W \approx r_c$ é a largura de banda disponível no sistema. Normalmente, θ_i pode ser aproximado por [Sampaio et al. 2010]:

$$\theta_i = -\frac{1.5}{\log(5\text{BER}_i^{\text{MAX}})} \quad (2.13)$$

onde $\text{BER}_i^{\text{MAX}}$ é a máxima taxa de erro de bit tolerável para o serviço do i -ésimo usuário. Portanto, o fluxo máximo de informação (considerando todos os usuários) alcançável é dado por:

$$\mathcal{V} = \sum_{i=1}^U r_i \leq r_c \cdot \sum_{i=1}^U \frac{\log_2(1 + \theta_i \gamma_i)}{F_i \cdot m_i} \quad (2.14)$$

A fim de permitir que os usuários possuam garantia mínima de QoS, a relação entre CINR e SNIR mínima pode ser calculada como segue [Elmusrati, El-Sallabi e Koivo 2008]:

$$\Gamma_{i,\min} = \frac{r_{i,\min}}{r_c} \cdot \gamma_i^*, \quad i = 1, \dots, U \quad (2.15)$$

onde $\Gamma_{i,\min}$ e $r_{i,\min}$ são a mínima CIR e a mínima taxa de informação necessária para garantir o serviço do i -ésimo usuário, respectivamente, e γ_i^* é a mínima SNIR necessária para se obter um QoS aceitável para o usuário, associado à máxima BER permitida para cada classe de serviço.

Portanto, a taxa de informação mínima pode ser mapeada em SNIR através do modelo de capacidade de canal Shannon, utilizando o *gap* introduzido na equação (2.12):

$$2^{\frac{r_i m_i}{w_i}} \leq 1 + \theta_i \gamma_i = 1 + \frac{\theta_i F_i \cdot p_i |g_{ii}|^2}{\sum_{i \neq j}^U p_j |g_{ij}|^2 + \sigma^2} \quad (2.16)$$

onde $2^{\frac{r_i m_i}{w_i}}$ é a taxa de informação normalizada para o i -ésimo usuário. Nota-se que para a SNIR mínima γ_i^* , a equação (2.16) utiliza a taxa de informação mínima estabelecida pelo sistema, objetivando garantir QoS. Assim, é possível obter a condição necessária em termos de SNIR para garantir o serviço, dada a taxa de informação mínima e a BER máxima tolerável por usuário:

$$\gamma_i^* = \frac{2^{\frac{r_i m_i}{w_i}} - 1}{\theta_i} \quad (2.17)$$

Além da relação obtida na equação (2.17), é possível manipular este resultado algebricamente e verificar que a SNIR mínima depende diretamente da BER máxima tolerável, bem como da taxa de informação mínima requerida pelo serviço [Proakis 2000]:

$$\gamma_i^* = -\frac{2}{3} \ln(5 \cdot \text{BER}_i^{\text{MAX}}) (2^{m_i} - 1) \quad (2.18)$$

2.2 Estratégias de Controle de Potência em Redes CDMA

Dada a escassez e o alto custo de recursos naturais como energia e espectro, vários estudos vem sendo realizados no âmbito da alocação de recursos em redes de múltiplo acesso, a fim de propor novas técnicas que melhor utilizem estes recursos. Uma das formas de se economizar bateria, e ao mesmo tempo melhorar o uso do espectro dado o aumento da capacidade do sistema em número de usuários, é fazer com que todos os terminais móveis e estações rádio-base operem no ponto em que todos utilizem o mínimo nível de potência necessário para seja possível uma transmissão com garantia mínima de QoS.

2.2.1 O Problema de Alocação de Potência Mínima

O objetivo do problema de alocação de potência mínima (MPA) é encontrar a mínima potência de transmissão para cada usuário do sistema satisfazendo, ao mesmo tempo, todos os requisitos de QoS. Uma vez que os requisitos de QoS resumem-se basicamente à mínima taxa de informação, e máxima BER tolerável, e que por sua vez, estes podem ser resumidos em SNIR, pode-se utilizar a SNIR como restrição para a garantia de QoS. Portanto, o problema de controle de potência pode ser matematicamente descrito como:

$$\begin{aligned} \min \quad & \mathbf{p} = [p_1, p_2, \dots, p_U] \\ \text{s.t.} \quad & \gamma_i \geq \gamma_i^* \\ & 0 \leq p_i \leq p_{\max} \end{aligned} \quad (2.19)$$

onde p_i e γ_i são a potência de transmissão e a SNIR do i -ésimo usuário, respectivamente, e γ_i^* a mínima SNIR necessária para que se possa garantir o serviço do i -ésimo usuário.

A fim de resolver este problema de forma determinística, a matriz de interferência normalizada \mathbf{B} é considerada [GROSS, ABRAO e JESZENSKY 2011]:

$$B_{ij} = \begin{cases} 0, & i = j; \\ \frac{\Gamma_{i,\min} g_{ji}}{g_{ii}}, & \text{caso contrário.} \end{cases} \quad (2.20)$$

onde $\Gamma_{i,\min}$ pode ser obtida a partir da equação (2.15).

Considerando os requisitos de taxa de informação para cada usuário, e o vetor de ruído normalizado $\mathbf{u} = [u_1, u_2, \dots, u_k]^T$, cujos elementos são:

$$u_i = \frac{\Gamma_{i,\min} \sigma_i^2}{g_{ii}} \quad (2.21)$$

A solução para o problema de controle de potência pode ser obtida analiticamente através da solução do seguinte sistema linear [Elkamchouchi, Elragal e Makar 2007]:

$$\mathbf{p}^* = (\mathbf{I} - \mathbf{B})^{-1} \mathbf{u} \quad (2.22)$$

onde $\mathbf{I}_{U \times U}$ é a matriz identidade. Note que $(\mathbf{I} - \mathbf{B})$ é inversível se, e somente se o maior autovalor de \mathbf{B} é menor que um [Seneta 2006]. Somente neste caso, o problema de controle de potência vai apresentar uma solução factível. Não obstante, devido aos recursos limitados dos terminais móveis, o uso deste método não é viável uma vez que seu custo computacional cresce proibitivamente na ordem de $\mathcal{O}(n^3)$ quando o número de usuários vai além de algumas dezenas devido à operação de inversão de matriz. Além disso, não é possível obter uma solução completamente distribuída a partir desta abordagem analítica. A fim de contornar os problemas apresentados, uma abordagem meta-heurística foi proposta neste trabalho para o problema de alocação de potência mínima.

A fim de utilizar o algoritmo contínuo de otimização por colônia de formigas ($\text{ACO}_{\mathbb{R}}$) para resolver o problema de alocação de potência mínima, uma representação matemática do problema faz-se necessária, considerando os objetivos e restrições aplicadas. À esta representação, dá-se o nome de função custo, ou função objetivo, e será assim nomeada no decorrer deste trabalho. Em [Moustafa, Habib e Naghshineh 2001], uma função custo para o controle de potência

utilizando o algoritmo genético foi proposta. Esta função foi modificada posteriormente, e utilizada com o algoritmo de otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) em [Abrão et al. 2011] para resolver também o problema de alocação de potência mínima. Devido aos bons resultados obtidos em [Abrão et al. 2011], tal função custo foi utilizada com o algoritmo $\text{ACO}_{\mathbb{R}}$, como segue:

$$\begin{aligned} \max_{\mathbf{p} \in \mathfrak{P}} J_1(\mathbf{p}) &= \frac{1}{U} \sum_{i=1}^U \mathbb{F}_i^{\text{th}} \cdot \left(1 - \frac{p_i}{p_{\max}}\right), & \forall i = 1, 2, \dots, U \\ \text{s.t.} & \quad \gamma_i \geq \gamma_i^* \\ & \quad 0 \leq p_i \leq p_{\max} \\ & \quad r_i = r_{i,\min} \end{aligned} \quad (2.23)$$

onde a função *threshold* é definida como $\mathbb{F}_i^{\text{th}} = \begin{cases} 1, & \gamma_i \geq \gamma_i^* \\ 0, & \text{caso contrário} \end{cases}$

e o vetor de potência alocada descrito por:

$$\mathbf{p} \in \mathfrak{P} \stackrel{\text{def}}{=} \{[p_i]_{1 \times U} \mid 0 \leq p_i \leq p_{\max}\} \quad (2.24)$$

Sabe-se na literatura que o problema de atribuição de potência mínima com requisitos de QoS não é de simples resolução, principalmente quando o número de usuários vai além de algumas dezenas. Isso porque tal problema não é de natureza convexa, e portanto as funções custo que o modelam possuem grande número de ótimos locais, o que dificulta sua resolução, mesmo para meta-heurísticas.

Não obstante, outros modos de operação para sistemas de comunicação sem fio que aproveitam o espectro e a energia de forma eficaz, e ao mesmo tempo possuem natureza convexa foram propostos.

2.2.2 O Problema da Maximização da Vazão (WTM)

A crescente demanda por tráfego de informações devido aos serviços de multimídia incorporados a partir da terceira geração (3G) da telefonia celular, em conjunto com a necessidade de incrementar os lucros das companhias de telecomunicações, motivaram os trabalhos em algoritmos que maximizem a eficiência espectral do sistema (SE). Com isso, o problema de maximização do fluxo de informação ponderado (*Weighted Throughput Maximization* - WTM), que visa maximizar a taxa de informação total do sistema foi proposto, como segue [Mar-

ques et al. 2012, Qian, Zhang e Huang 2008]:

$$\begin{aligned} \max_{\mathbf{p} \in \mathcal{P}} \quad & f(\mathbf{p}) \\ \text{s.t.} \quad & r_i \geq r_{i,\min} \\ & 0 \leq p_i \leq p_{\max} \end{aligned} \quad (2.25)$$

onde $f(\mathbf{p})$ é uma função custo que objetiva maximizar a taxa de informação de cada usuário; r_i é a taxa de informação do i -ésimo usuário, $r_{i,\min}$ a taxa mínima necessária para garantir QoS, \mathbf{p} é o vetor de potências tal que $\mathbf{p} = [p_1, p_2, \dots, p_U]$, e p_{\max} é a potência de transmissão máxima permitida no sistema.

Ademais, é necessário incorporar o critério multi-taxa ao problema WTM. Então, o problema de otimização é formulado como um caso especial de programação linear fracional generalizada (*Generalized Linear Fractional Programming* - GLFP) [Qian, Zhang e Huang 2008]. Desta forma, o problema pode ser descrito como segue:

$$\begin{aligned} \max_{\mathbf{p} \in \mathcal{P}} \quad & \underline{J}(\mathbf{p}) = \prod_{i=1}^U \left[\frac{f_i(\mathbf{p})}{h_i(\mathbf{p})} \right]^{v_i} \\ \text{s.t.} \quad & 0 < p_i \leq p_{i,\max}, \\ & \gamma_i \geq \gamma_i^*, \quad \forall i = 1, \dots, U \end{aligned} \quad (2.26)$$

onde $v_i > 0$ é a prioridade para o i -ésimo usuário transmitir com seus requisitos de QoS satisfeitos, assumido normalizado, de forma que $\sum_{i=1}^U v_i = 1$. Conforme já apresentado neste trabalho, a segunda restrição da equação (2.26) visa a garantia de SNIR mínima para todos os usuários, e com isso, a garantia de QoS. As funções $f_i(\mathbf{p})$ e $h_i(\mathbf{p})$ podem ser definidas como:

$$\begin{aligned} h_i(\mathbf{p}) &= \sum_{j \neq i}^U p_j |g_{ij}|^2 + \sigma^2 \\ f_i(\mathbf{p}) &= \theta F_i \cdot p_i |g_{ii}|^2 + h_i(\mathbf{p}), \quad \forall i = 1, \dots, U. \end{aligned} \quad (2.27)$$

Note que a equação (2.26) é o produtório de funções lineares fracionais exponenciadas, e a função $\prod_{i=1}^U (z_i)^{v_i}$ é crescente no intervalo real não negativo [Qian, Zhang e Huang 2008]. Baseado nestas propriedades, o problema (2.25) pode ser reescrito como:

$$\begin{aligned} \max_{\mathbf{p} \in \mathcal{P}} J_2(\mathbf{p}) &= \sum_{i=1}^U v_i [\log_2 f_i(\mathbf{p}) - \log_2 h_i(\mathbf{p})] \\ &= \sum_{i=1}^U v_i [\bar{f}_i(\mathbf{p}) - \bar{h}_i(\mathbf{p})] \end{aligned} \quad (2.28)$$

$$\text{s.t. (C.1)} \quad 0 < p_i \leq p_{i,\max}, \quad \forall i = 1, \dots, U$$

$$\text{(C.2)} \quad \gamma_i \geq \gamma_i^*, \quad \forall i = 1, \dots, U$$

Neste trabalho, os pesos v_i foram formulados de acordo com o tipo de serviço utilizado pelo usuário, que em sistemas MPG-DS/CDMA, é determinado pelo ganho de processamento:

$$v_i = \frac{1}{F_i} \left[\sum_{j=1}^U \left(\frac{1}{F_j} \right) \right]^{-1}, \quad \forall i \quad (2.29)$$

Portanto, a função custo se torna um somatório de logaritmos, que resulta em uma função monotonicamente não-decrescente.

Um fator importante a ser considerado no WTM está relacionado às demandas de várias taxas de informação por diferentes serviços em termos de SNIR mínima. A abordagem de SNIR fixa para o controle de potência discutida em [Marques et al. 2012] é considerável para redes levemente carregadas, e de serviço único. Isto pois, quando o carregamento da rede aumenta, configurar a SNIR mínima γ^* em níveis factíveis torna-se uma tarefa desafiadora, principalmente em termos computacionais. Além disso, em redes sem fio multi-serviço (ex. voz, vídeo e dados), a atribuição de SNIRs pode ser otimizada de acordo com os requisitos de tráfego, e com as condições do canal. Maiores SNIRs implicam em maiores taxas de informação, e conseqüentemente aumentam a confiabilidade da rede. Os operadores das redes CDMA tratam usuários de altas taxas de informação de forma diferente, de forma que os usuários que pagam por serviços de maior valor obtém bons valores de SNIR preferencialmente. Com isso, diferentes valores de SNIR mínima precisam ser atribuídos a usuários de diferentes classes. Portanto, definir a taxa de informação (2.12), ou qualquer outra métrica de QoS como um mapeamento bijetivo à SNIR, e otimizar a alocação do mesmo de forma factível e de acordo com uma função custo não é uma tarefa fácil. Portanto, na prática, o problema se torna a atribuição de SNIRs e o controle de potências [Chiang et al. 2007].

2.2.3 O Problema da Maximização da Eficiência Energética

A maximização da eficiência energética total η_E em sistemas DS/CDMA pode ser formulada como um problema de otimização que objetiva maximizar a razão entre a taxa de informação total do sistema \mathcal{V} , pelo nível de potência consumida $P_t = \iota \sum_i^U p_i + P_c$, incluindo a potência transmitida p_i e a potência de circuitaria P_c , que é considerada fixa durante o processo de otimização; o parâmetro $\iota > 1$ está relacionado ao inverso da ineficiência do amplificador RF.

O problema de maximização da eficiência energética total em sistemas MPG-DS/CDMA pode ser formulado como:

$$\begin{aligned} \max_{\mathbf{p} \in \mathcal{P}} \quad \eta_E = \frac{\mathcal{V}}{P_T} &= \sum_{i=1}^U \frac{\frac{w_i}{m_i} \cdot \log_2(1 + \theta_i \gamma_i)}{\iota \cdot \sum_i^U p_i + P_c} \quad \left[\frac{\text{bit}}{\text{Joule}} \right] \\ \text{s.t. (C.1)} \quad 0 &\leq p_i \leq p_{\max} \\ \text{(C.2)} \quad \gamma_i &\geq \gamma_i^*, \quad \forall i \\ \text{(C.3)} \quad r_i &\geq r_{i,\min}^{\text{serv}} \end{aligned} \quad (2.30)$$

$$\text{com} \quad (1 + \theta_i \gamma_i) = 1 + \frac{\theta_i F_i \cdot p_i |g_{ii}|^2}{\sum_{i \neq j}^U p_j |g_{ij}|^2 + \sigma^2}$$

onde $p_{\max,i}$ é a máxima potência de transmissão disponível ao i -ésimo usuário, e $\sum_{i=1}^U p_i \leq P_{\max}$, com P_{\max} representando a potência de transmissão disponível na estação rádio base (ERB).

O problema de otimização da Eficiência Energética (EE, η_E) consiste em encontrar a potência de transmissão apropriada à cada usuário pertencente às diferentes classes de multimídia, nomeadas $\text{SERV} = \{\text{VOZ}, \text{VÍDEO}, \text{DADOS}\}$, com diferentes requisitos mínimos de QoS, que podem ser mapeados em SNIR. Além disso, e como já fora visto neste trabalho, a restrição (C.3) pode se mapeada em (C.2). Com isso, a função da eficiência energética total do sistema (2.30) pode ser maximizada, encontrando o vetor de potências capaz de fazer com que o sistema opere no ponto de EE. Vale ressaltar que o ponto de máxima EE não necessariamente corresponde ao ponto de máxima eficiência espectral (*Spectral Efficiency* - SE), especialmente nos casos em que há potência de transmissão suficiente disponível no transmissor. No entanto, os problemas encontrados no compromisso EE-SE estão fora do escopo deste trabalho.

A função custo para a maximização da EE (2.30) pode ser classificada como um programa fracional não linear [Dinkelbach 1967, Schaible 1976]. Isso pois,

tal função é a razão entre duas outras funções, que geralmente resultam em programas fracionais não-côncavos. Na verdade, o numerador de (2.30) é côncavo em relação às variáveis $p_i, \forall i$, uma vez que é a soma não-negativa de funções côncavas. Além disso, o denominador é afim, ou seja, convexo e côncavo (linear) em relação à \mathbf{p} . Os programas em que a função do numerador é côncava, e a do denominador é convexa são chamados de programas fracionais quase-côncavos [Schaible e Ibaraki 1983]. As provas para estas afirmações serão apresentadas no apêndice A.

Os programas fracionais côncavos compartilham importantes propriedades com os programas côncavo-convexos (não fracionais). Tais propriedades foram apresentadas em [Schaible e Ibaraki 1983, Avriel et al. 2010], e serão listadas abaixo:

- (i) Se um programa fracional é quase-côncavo, existe apenas um ótimo local na função custo, e este ótimo também é global;
- (ii) Um ótimo local é único se a função no numerador for estritamente côncava, ou a do denominador estritamente convexa;
- (iii) Uma solução das condições de otimalidade de *Karush-Kuhn-Tucker* (KKT) é um máximo se as funções do numerador e do denominador forem diferenciáveis no conjunto aberto \mathcal{C} ;
- (iv) Se existir uma solução ótima, um máximo é obtido em uma das extremidades do polígono convexo \mathcal{X} de um programa fracional linear.

Devido às propriedades apresentadas, é possível resolver programas fracionais côncavos através de ferramentas normalmente utilizadas para resolver programas côncavo-convexos [Avriel et al. 2010]. Por exemplo, a propriedade (iv) sugere que é possível resolver um programa fracional linear utilizando ferramentas baseadas no método simplex.

Uma forma muito utilizada para a resolução de programas fracionais é resolver um programa paramétrico equivalente, que muitas vezes é mais interessante do que resolver o problema original. Tal técnica é nomeada por Método de Dinkelbach (*Dinkelbach's Method* - DM), e será apresentada a seguir.

2.2.3.1 O método de Dinkelbach

O método iterativo de Dinkelbach [Dinkelbach 1967] foi proposto a fim de resolver programas fracionais através de programas paramétricos equivalentes.

Isso reduz a complexidade de resolução do problema, uma vez que o método simplesmente encontra a raiz o problema paramétrico, similarmente ao método de Newton. Portanto, é possível resolver o problema fracional quase-côncavo de maximização da EE total de um sistema MPG-DS/CDMA através do método de Dinkelbach. De maneira geral, o programa fracional côncavo original pode ser representado como segue:

$$(\mathcal{Q}) \quad \max_{x \in \mathcal{X}} \quad \kappa(x) = \frac{f(x)}{z(x)}, \quad (2.31)$$

onde \mathcal{X} é um conjunto compacto e conexo, e $z(x) > 0$ é assumido. Além disso, por razões de simplicidade de notação, define-se $\mathcal{X} \supset \{\emptyset\}$ como o conjunto de soluções factíveis do problema (2.30). O programa fracional original da equação (2.31) pode ser associado com o seguinte programa paramétrico côncavo [Dinkelbach 1967, Schaible 1976]:

$$(\mathcal{Q})_P \quad \max_{x \in \mathcal{X}} \quad F(\kappa) = f(x) - \kappa z(x) \quad (2.32)$$

onde $\kappa \in \mathbb{R}$ é tratado como um parâmetro. O formato da função objetivo no problema paramétrico quando x é ótimo, denotado de $F(\kappa)$, é uma função convexa contínua que é estritamente decrescente.

Definição 2.2.1. *Encontrar a raiz do programa paramétrico $(\mathcal{Q})_P$, $F(\kappa) = 0$, equivale à obter a solução ótima do programa fracional (\mathcal{Q}) [Crouzeix e Ferland 1991].*

Portanto, a partir da definição 2.2.1, pode-se definir o ponto de máxima eficiência energética total κ^* do sistema considerado como sendo:

$$\kappa^* = \frac{\mathcal{C}(\mathbf{p}^*)}{\mathcal{U}(\mathbf{p}^*)} = \max_{\mathbf{p} \in \mathcal{P}} \frac{\mathcal{C}(\mathbf{p})}{\mathcal{U}(\mathbf{p})} \quad (2.33)$$

i.e.,
$$\begin{cases} F(\kappa) > 0 & \Leftrightarrow \kappa < \kappa^* \\ F(\kappa) = 0 & \Leftrightarrow \kappa = \kappa^* \\ F(\kappa) < 0 & \Leftrightarrow \kappa > \kappa^* \end{cases}$$

Portanto, o método de Dinkelbach apresentado no Algoritmo 1 resolve o seguinte problema:

$$\max_{\mathbf{p} \in \mathcal{P}} \quad \mathcal{C}(\mathbf{p}) - \kappa \mathcal{U}(\mathbf{p}), \quad (\text{D.M.}) \quad (2.34)$$

que é equivalente a encontrar a raiz da equação não linear $F(\kappa) = 0$.

Algorithm 1 O Método de Dinkelbach

Entrada: κ_0 satisfazendo $F(\kappa_0) \geq 0$; tolerância ϵ

Inicializar: $t \leftarrow 0$,

repita

Resolva o problema (2.34) com $\kappa = \kappa_n$ para obter \mathbf{p}^*

$\kappa_{t+1} \leftarrow \frac{\mathcal{C}(\mathbf{p}^*)}{\mathcal{U}(\mathbf{p}^*)}$;

$t \leftarrow t + 1$

até $|F(\kappa_t)| \leq \epsilon$;

Saída: κ_t ; \mathbf{p}_t

Como visto, o método de Dinkelbach nada mais é que a aplicação do método de Newton a um programa fracional não linear [Schaible e Ibaraki 1983]. Como resultado, a sequência converge para o ponto de ótimo do problema original super-linearmente. Resumidamente, o método de Dinkelbach [Dinkelbach 1967] propõe um método iterativo para encontrar valores crescentes e factíveis de κ , resolvendo o problema parametrizado:

$$\max_{\mathbf{p}} F(\kappa_t) = \max_{\mathbf{p}} \{ \mathcal{C}(\mathbf{p}) - \kappa_t \mathcal{U}(\mathbf{p}) \} \quad \text{@}t\text{-ésima iteração.} \quad (2.35)$$

O processo iterativo continua até que o valor absoluto de $|F(\kappa_t)|$ torne-se menor que uma tolerância positiva pré-especificada ϵ .

A fim de demonstrar a efetividade do DM, resultados ilustrativos da maximização da $\sum EE$ para sistemas MPG-DS/CDMA são discutidos na seção 4.3.3. O *loop* interno no Algoritmo 1 foi realizado primeiramente pela ferramenta de otimização CVX, um pacote para especificar e resolver problemas convexos [CVX Research, Inc. 2012, Grant e Boyd 2008]; e em segundo lugar, o *loop* interno foi resolvido pelos algoritmos meta-heurísticos ACO_ℝ [Socha e Dorigo 2008] e PSO [Kennedy e Eberhart 1995].

3 Meta-Heurísticas Bio-Inspiradas

As Meta-heurísticas Bio-inspiradas são uma abordagem alternativa para a resolução de problemas de otimização que, apesar de não garantir soluções ótimas, alcançam soluções aceitáveis com baixa complexidade computacional. Neste contexto, estas vêm sendo cada vez mais utilizadas para resolver problemas do tipo NP-Completo (classe de problemas em que se acredita ser impossível a elaboração de algoritmos capazes de resolvê-los em tempo polinomial) em diversas áreas.

O $ACO_{\mathbb{R}}$ e o PSO são duas técnicas evolucionárias baseadas na cooperação entre indivíduos de uma determinada população, diferindo assim de heurísticas clássicas como os Algoritmos Genéticos. Sendo assim, objetiva-se aplica-los aos problemas de alocação de recursos apresentados.

3.1 O $ACO_{\mathbb{R}}$

O $ACO_{\mathbb{R}}$ é uma meta-heurística baseada no comportamento de formigas em busca de comida. Note que ela foi primeiramente proposta para problemas de otimização combinatória. Em tal versão, cada formiga caminha através dos pontos do conjunto de entrada, e deposita feromônio em suas arestas. A escolha do próximo ponto é realizada probabilisticamente, considerando a quantidade de feromônio em cada aresta, em conjunto com a informação heurística (isto é, o inverso do custo da aresta).

Dado um conjunto de pontos próximo a uma formiga, a probabilidade de cada um desses pontos ser escolhido forma uma função de massa de probabilidade (PMF). A idéia principal do $ACO_{\mathbb{R}}$ é a substituição desta PMF por uma função de densidade de probabilidade (PDF), desta forma, a formiga amostra uma PDF contínua ao invés de escolher um ponto próximo à ela. A substituição realizada é devido ao fato de que em problemas de domínio contínuo (ex. controle de potência), existem infinitos pontos para serem escolhidos. Uma outra alternativa

seria manter a PMF utilizada para problemas de otimização combinatória, e discretizar o domínio do problema contínuo. Apesar disso, esta abordagem não foi realizada neste trabalho.

A PDF utilizada neste trabalho é a PDF gaussiana, dado que ela possui um único máximo localizado na média do processo. No entanto, esta característica não é útil quando o espaço de busca possui mais de uma região factível. A fim de contornar este problema, o ACO_ℝ utiliza uma PDF de núcleo gaussiano, que nada mais é do que um somatório ponderado de gaussianas para amostrar cada dimensão do problema. Cada PDF de núcleo gaussiano pode ser definida como segue [Socha e Dorigo 2008]:

$$\mathcal{G}^i(x) = \sum_{l=1}^L \rho_l \mathcal{N}(\mu_l^i, \sigma_l^i) = \sum_{l=1}^L \rho_l \frac{1}{\sigma_l^i \sqrt{2\pi}} e^{-\frac{(x-\mu_l^i)^2}{2\sigma_l^{i2}}}, \quad (3.1)$$

onde $i = 1, \dots, U$ é o indexador de PDFs de núcleo gaussiano (ou dimensões), com U sendo o número de dimensões do problema; $\boldsymbol{\rho} = [\rho_1, \rho_2, \dots, \rho_L]$ é o vetor de pesos associado à cada gaussiana no núcleo; $\boldsymbol{\mu}^i = [\mu_1^i, \mu_2^i, \dots, \mu_L^i]$ é o vetor de médias e $\boldsymbol{\sigma}^i = [\sigma_1^i, \sigma_2^i, \dots, \sigma_L^i]$ e o vetor de desvios padrão. Assim, a cardinalidade de todos os vetores é igual ao número de gaussianas no conjunto, $|\boldsymbol{\rho}| = |\boldsymbol{\mu}^i| = |\boldsymbol{\sigma}^i| = L$.

Na versão do ACO para problemas de otimização combinatória, as informações de feromônio são mantidas em uma tabela. Isso não é possível quando há a necessidade de lidar com problemas contínuos, uma vez que existem infinitos pontos para manter, e como consequência, infinitas maneiras de evoluir. Portanto, um arquivo de soluções é utilizado, onde a l -ésima solução $s_l, \forall l = 1, 2, \dots, L$, na i -ésima dimensão, $\forall i = 1, \dots, U$ é mantido no arquivo de memória na t -ésima iteração, assim como os valores da respectiva função custo $J(s_l)$.

As soluções encontradas são utilizadas para gerar PDFs dinamicamente, através de um método baseado nas soluções armazenadas. Os vetores $\boldsymbol{\mu}^i$ e $\boldsymbol{\sigma}^i$ na i -ésima dimensão e $\boldsymbol{\rho}$ comumente para todas as dimensões são calculados através das soluções do arquivo em cada iteração do algoritmo. Desta forma, o núcleo de PDFs gaussianas pode ser construído, e guiar as formigas através das dimensões do problema.

O arquivo de soluções deve armazenar L soluções. Note que este número é igual ao número de PDFs gaussianas ($\mathcal{N}(\mu_l^i, \sigma_l^i)$) no i -ésimo núcleo (\mathcal{G}^i). Portanto, pode-se concluir que o i -ésimo núcleo vai possuir uma PDF gaussiana amostrando cada i -ésima variável de cada solução. Desta forma, quanto maior o tamanho do

arquivo de soluções (L), maior será o número de gaussianas no núcleo. Portanto, o parâmetro L é um dos responsáveis pela complexidade do algoritmo. Além disso, para cada \mathcal{G}^i , os valores da i -ésima variável de todas as soluções se tornam os elementos do vetor de médias, $\boldsymbol{\mu}^i = [\mu_1^i, \dots, \mu_L^i] = [s_1^i, \dots, s_L^i]$, ou seja, o l -ésimo valor na dimensão i é a média da l -ésima gaussiana de \mathcal{G}^i .

Além disso, o número de formigas (ou partículas) M_{ACO} é um outro parâmetro de entrada importante do algoritmo ACO_ℝ. As formigas são responsáveis pela amostragem de \mathcal{G}^i , e portanto, pela evolução do algoritmo como um todo. Desta maneira, em cada iteração, cada formiga escolhe uma solução do arquivo probabilisticamente. Uma vez que a formiga tenha escolhido uma solução do arquivo, o próximo passo consiste em amostrar as gaussianas através de \mathcal{G}^i . Feito isto, uma nova solução é gerada e colocada no fim do arquivo. Assim que a última formiga terminar sua amostragem, o arquivo de soluções é ordenado baseado no vetor que armazena os valores de cada solução aplicada na função custo $\mathbf{J} = [J(s_1), \dots, J(s_l), \dots, J(s_L)]$. Portanto, para os problemas descritos no capítulo 2, a matriz $\mathbf{J} \equiv f(\mathbf{p})$ deve ser ordenada de forma decrescente, ex., $J(s_1) \geq J(s_2) \geq \dots \geq J(s_L)$.

Quando o processo de ordenação é finalizado, um número de soluções localizadas no final do arquivo é descartado, que por sua vez, é igual ao número de soluções geradas no processo de amostragem. Nota-se que uma vez que cada formiga amostra apenas uma solução em cada iteração, o número de soluções a ser descartado é igual à M_{ACO} .

Neste ponto, uma PDF de núcleo gaussiano (\mathcal{G}^i) está definida para cada dimensão do problema, em que a l -ésima variável torna-se elemento do vetor $\boldsymbol{\mu}^i$. Portanto, considerando a \mathcal{G}^i definida na i -ésima dimensão, o peso ρ_l de cada solução é calculado como segue:

$$\rho_l = \frac{1}{qL\sqrt{2\pi}} \exp \left[-\frac{(l-1)^2}{2q^2L^2} \right], \quad l = 1, \dots, L \quad (3.2)$$

Assim, o peso da l -ésima solução pode ser visto como a probabilidade desta solução ser escolhida e amostrada por uma formiga. Portanto, o valor l que por sua vez é o *ranking* da l -ésima solução no arquivo, é também a entrada da equação (3.2), que é uma PDF gaussiana de média 1 e desvio padrão $q \cdot L$, onde q é um parâmetro de entrada do algoritmo ACO_ℝ. O parâmetro q pode ser visto como um parâmetro de diversificação, onde pequenos valores de q aumentam a velocidade de convergência do algoritmo; por outro lado, grandes valores de q

aumentam a robustez do algoritmo. Isso é devido ao fato de que, na distribuição normal para o cálculo do peso da l -ésima solução (Eq. (3.2)), quanto maior for o valor do desvio padrão, mais chances as soluções que estão longe da média têm de ser escolhidas, fazendo com que o algoritmo aumente o seu espaço de busca (maior diversidade). Vale ressaltar que a média do processo é a primeira solução do arquivo. Então, quando o desvio padrão $q \cdot L$ assume pequenos valores, apenas as melhores soluções do arquivo serão selecionadas, aumentando a velocidade de convergência. Desta forma, o parâmetro q corresponde aos conceitos de solução *best-so-far* e solução *iteration-best* [Socha e Dorigo 2008].

Definição 3.1.1. *Para algoritmos meta-heurísticos, é chamado solução best-so-far o processo de evoluir baseado na melhor solução encontrada no início da execução do algoritmo. Isso faz com que o mesmo aumente sua velocidade de convergência, já que é assumido que a solução inicial está próxima do ótimo da função custo (melhor caso).*

Definição 3.1.2. *Quando o processo de evolução do algoritmo meta-heurístico é baseado na melhor solução encontrada na última iteração, o processo de evolução é nomeado iteration-best. Isso faz com que o algoritmo aumente sua robustez, uma vez que é assumido que a solução inicial está longe do ótimo da função custo (pior caso).*

Assim, a equação (3.2) representa um importante equilíbrio entre os parâmetros q e L , fazendo suas calibrações individuais sensíveis entre si, a fim de obter um bom compromisso entre robustez e velocidade de convergência para cada problema de otimização específico.

Ademais, a escolha do tamanho da população M_{ACO} também representa um papel importante para melhorar o compromisso robustez-velocidade, em conjunto com o melhor valor de $q \cdot L$ obtível. Note que o parâmetro M_{ACO} pode ser sobrecarregado a fim de aumentar a capacidade do algoritmo, ao custo indesejável de maior complexidade computacional. Finalmente, a robustez \mathcal{R} pode ser vista como a razão entre o número de sucessos de convergência do algoritmo cS e o total de realizações do processo de otimização \mathcal{T} depois de T iterações em cada realização:

$$\mathcal{R} = \frac{cS}{\mathcal{T}} \cdot 100 \quad [\%] \quad @T \text{ iterations} \quad (3.3)$$

e a velocidade como a média do número de iterações necessárias para o algoritmo atingir a convergência em \mathcal{T} realizações do dado problema.

A seguir, os passos essenciais da implementação do algoritmo ACO_ℝ são discutidos, como a estrutura geral do ACO_ℝ, o cálculo do vetor σ^i , bem como o processo de amostragem. O Algoritmo 2 descreve a organização geral do algoritmo; as funções apresentadas são descritas a seguir.

Algorithm 2 Visão Geral do ACO

while *As condições de parada não forem satisfeitas* **do**

Construção de Soluções

Atualização de Feromônio

Ações Centralizadas

end while

Construção de Soluções: Através das variáveis de decisão de cada solução $s_l^i, i = 1, \dots, U$, cada formiga constrói uma solução em U passos. A fim de amostrar \mathcal{G}^i , os vetores μ^i, σ^i e ρ devem ser atualizados. Na prática, o processo de amostragem é realizado em três etapas: (a) Primeiro, os elementos do vetor ρ devem ser calculados, onde deve ser notado que o parâmetro l (o *ranking* das soluções) nunca vai ser alterado, independentemente das mudanças na ordem das soluções no arquivo. (b) Na segunda etapa, cada formiga deve escolher uma solução do arquivo visando amostrá-la, e a probabilidade desta escolha (P_l) deve ser relativa à normalização de cada peso de solução pelo somatório de todos os pesos:

$$P_l = \rho_l \cdot \left(\sum_{r=1}^k \rho_r \right)^{-1} \quad (3.4)$$

Assim, uma vez que a formiga tenha escolhido sua solução, esta deve ser amostrada passo a passo utilizando um gerador normal de número aleatórios. Portanto, considere s_l como sendo a solução escolhida por uma formiga durante o processo de evolução do algoritmo. A formiga amostra s_l dimensionalmente, além disso, a amostragem é realizada através de uma função gaussiana parametrizada pelos valores μ_l^i e σ_l^i . Portanto, σ_l^i é calculado para a i -ésima dimensão como segue:

$$\sigma_l^i = \xi \sum_{e=1}^k \frac{|s_e^i - s_l^i|}{k-1} \quad (3.5)$$

Aqui, o valor de σ_l^i para s_l^i é a distância média de s_l^i para os outros valores da dimensão i nas outras soluções do arquivo. O processo é repetido até a última

dimensão do arquivo. Desta forma, quanto maior a variabilidade das diferentes soluções, maior será o valor do desvio padrão σ_l^i . Note que o parâmetro $\xi \in [0, 1]$ objetiva reduzir o desvio padrão, trabalhando como um fator de aprendizagem. Uma vez que o valor de σ_l^i é calculado, a formiga vai amostrar a PDF gaussiana $\mathcal{N}(\mu_l^i, \sigma_l^i)$.

O parâmetro ξ é o mesmo para todas as dimensões de todas as soluções, e corresponde à taxa de evaporação de feromônio, ou ao inverso da taxa de aprendizagem. Assim, quando o valor de ξ é pequeno a velocidade do algoritmo aumenta, e quanto é alto, a robustez do algoritmo aumenta. Vale ressaltar que o algoritmo converge quando σ se aproxima de zero em todas as dimensões, dada uma tolerância máxima ϵ_{ACO} .

Atualização de Feromônio: No início do algoritmo ACO_ℝ, o arquivo de soluções é inicializado com L soluções de forma uniformemente aleatória. A partir disso, a atualização de feromônio é feita adicionando as novas soluções geradas pelas formigas, bem como removendo o mesmo número de piores soluções.

Ademais, o tamanho L do arquivo de soluções é um parâmetro de entrada do algoritmo, e segundo [Socha e Dorigo 2008], não pode ser menor que o número de dimensões do problema, permitindo o tratamento de correlação de variáveis e suportando transformações lineares no problema sendo otimizado. Como neste trabalho, o tratamento de correlação de variáveis e as transformações lineares em problemas não foram utilizados, o parâmetro $L < U$ foi utilizado em quase todos os problemas. Vale ressaltar que, mesmo assim, o algoritmo obteve um desempenho satisfatório.

Finalmente, o tamanho do arquivo é o principal parâmetro de diversidade do algoritmo, uma vez que um grande arquivo vai cobrir maiores regiões no espaço de busca, fazendo com que o algoritmo possa contornar ótimos locais, mas por outro lado, um pequeno arquivo de soluções faz com que o algoritmo seja mais rápido.

Ações Centralizadas: Este componente é opcional no ACO_ℝ, e pode ser utilizado para implementar ações centralizadas que não são acessíveis às formigas (ex. transformações lineares no problema, e tratamento de correlação de variáveis). Neste estágio, a solução encontrada deve ser atualizada e retornada como solução final. Além disso, é possível implementar métodos de busca local aqui, mas este recurso não será explorado neste trabalho também, uma vez que o foco aqui é a redução da complexidade computacional.

3.2 O Algoritmo PSO Contínuo

O algoritmo PSO consiste em um grupo de partículas situadas no hiperespaço de busca \mathbb{R}^U que evoluem e tendem a convergir para o ponto de mínimo (máximo) global de um função custo. A posição de cada partícula é atualizada a cada iteração tendo em conta a velocidade da mesma. Desta forma, cada vetor candidato¹ no instante (iteração) t , definido como $\mathbf{b}_p[t]$ tem sua velocidade atualizada pela equação:

$$\mathbf{v}_p[t+1] = w[t] \cdot \mathbf{v}_p[t] + \phi_1 \cdot \mathbf{U}_{p1}[t] (\mathbf{b}_p^{best}[t] - \mathbf{b}_p[t]) + \phi_2 \cdot \mathbf{U}_{p2}[t] (\mathbf{b}_g^{best}[t] - \mathbf{b}_p[t]) \quad (3.6)$$

onde $w[t]$ é a inércia da velocidade no instante atual; $\mathbf{U}_{p1}[t]$ e $\mathbf{U}_{p2}[t]$ são matrizes diagonais de dimensão U cujos elementos são variáveis aleatórias de distribuição uniforme $\sim \mathcal{U} \in [0, 1]$, geradas para a p -ésima partícula na iteração $t = 1, 2, \dots, T$; $\mathbf{b}_p^{best}[t]$ e $\mathbf{b}_g^{best}[t]$ são, respectivamente, a melhor posição local e a melhor posição global encontradas até a t -ésima iteração; ϕ_1 e ϕ_2 são coeficientes de aceleração relativos a influência das soluções locais e da solução global, respectivamente. Na Figura 3.1 a velocidade é representada graficamente para uma partícula $\mathbf{b}_p[t]$ [Kennedy e Eberhart 1995].




Figura 3.1: Velocidade representada de maneira esquematizada em um plano cartesiano.

A evolução do PSO acontece de acordo com os candidatos com o menor valor

¹O termo vetor candidato é empregado aqui como sinônimo de partícula.

de função custo (*fitness*) satisfazendo as restrições da função objetivo. Sendo assim, cada vetor candidato $\mathbf{b}_p[t]$ de tamanho $U \times 1$ tem sua posição atualizada utilizando a nova velocidade calculada pela Equação ((3.6)), tal que:

$$\mathbf{b}_p[t + 1] = \mathbf{b}_p[t] + \mathbf{v}_p[t + 1], \forall p = 1, \dots, M_{\text{PSO}} \quad (3.7)$$

Desta forma, pode-se resumir o algoritmo PSO como a aplicação sucessiva das equações de atualização de velocidade e posição. O pseudo-código do PSO contínuo uni-objetivo é apresentado no Algoritmo 3.

Algorithm 3 PSO uni-objetivo para Alocação de Recursos

Entrada: $M_{\text{PSO}}, T_{\text{PSO}}, w, \phi_1, \phi_2, V_{\text{max}}$; **Saída:** \mathbf{p}^*

início

1. inicializar a primeira população: $t = 0$;
 $\mathbf{b}_p[0] \sim \mathcal{U}[p_{\text{min}}; p_{\text{max}}] \quad \forall p = 1, \dots, M_{\text{PSO}}$
 $\mathbf{b}_p^{\text{best}}[0] = \mathbf{b}_p[0]$ e $\mathbf{b}_g^{\text{best}}[0] = \mathbf{P}_{\text{max}}$;
 $\mathbf{v}_p[0] = \mathbf{0}$: velocidade inicial nula;
 2. enquanto $t \leq T_{\text{PSO}}$
 - a. calcule $J(\mathbf{b}_p[t]), \forall \mathbf{b}_p[t] \quad \forall p = 1, \dots, M_{\text{PSO}}$ usando a função custo do problema;
 - b. atualizar velocidade $\mathbf{v}_p[t], p = 1, \dots, M_{\text{PSO}}$, através de ((3.6));
 - c. atualizar melhores posições:
para $p = 1, \dots, M_{\text{PSO}}$
se $J(\mathbf{b}_p[t]) < J(\mathbf{b}_p^{\text{best}}[t]) \wedge r_p[t] \geq r_{p,\text{min}}$,
 $\mathbf{b}_p^{\text{best}}[t + 1] \leftarrow \mathbf{b}_p[t]$
senão $\mathbf{b}_p^{\text{best}}[t + 1] \leftarrow \mathbf{b}_p^{\text{best}}[t]$
fim para
se $\exists \mathbf{b}_p[t]$ tal que $[J(\mathbf{b}_p[t]) < J(\mathbf{b}_g^{\text{best}}[t])] \wedge r_p[t] \geq r_{p,\text{min}}$
 $\wedge [J(\mathbf{b}_p[t]) \leq J(\mathbf{b}_{p'}[t]), \forall p' \neq p]$,
 $\mathbf{b}_g^{\text{best}}[t + 1] \leftarrow \mathbf{b}_p[t]$
senão $\mathbf{b}_g^{\text{best}}[t + 1] \leftarrow \mathbf{b}_g^{\text{best}}[t]$
 - d. Evoluir para uma nova população $\mathbf{b}_p[t + 1] \quad \forall p = 1, \dots, M_{\text{PSO}}$, usando ((3.7));
 - e. set $t = t + 1$.
end
 3. $\mathbf{p}^* = \mathbf{b}_g^{\text{best}}[T_{\text{PSO}}]$.
- end

 M_{PSO} : tamanho da população.

T_{PSO} : número máximo de iterações.

\mathbf{p}_{max} : vetor de potências máximas para cada usuário.

A fim de reduzir a probabilidade da partícula sair do universo de busca o fator de velocidade máxima V_{max} é adicionado ao modelo do PSO ((3.6)), o qual será responsável por limitar o intervalo máximo de velocidade em $[\pm V_{\text{max}}]$. Esta restrição na velocidade permite que a partícula mova-se em um universo contínuo porém restrito a um subespaço, podendo ser aplicada da seguinte forma [Sampaio et al. 2010]:

$$v_p[t] = \min \{V_{\text{max}}; \max \{-V_{\text{max}}; v_p[t]\}\} \quad (3.8)$$

A partir de ((3.8)) fica claro que se $|v_p[t]|$ exceder um valor positivo constante V_{\max} especificado pelo usuário, a velocidade da *pésima* partícula é designada como $\text{sign}(v_p[t])V_{\max}$, i.e. a velocidade da partícula em cada uma das U - dimensões é fixada a uma magnitude máxima V_{\max} . Se for possível definir o espaço de busca num intervalo $[P_{\min}; P_{\max}]$, então o valor de V_{\max} tipicamente utilizado será $V_{\max} = \tau(P_{\max} - P_{\min})$, onde $0.1 \leq \tau \leq 1.0$.

Com o intuito de detalhar o estudo acerca do peso da inércia w nota-se que um valor relativamente alto contribui para encontrar ótimos globais, ofuscando a influência do valor das melhores posições da partícula e do bando², enquanto um pequeno valor de inércia tende a contribuir para a convergência, i.e. w com valores baixos contribui para a exploração local uma vez que as partículas passam a sofrer maior influência de $\mathbf{b}_p^{\text{best}}$ e $\mathbf{b}_g^{\text{best}}$ [Kennedy e Eberhart 1995].

Sendo assim, a fim de atingir um balanço entre as habilidades de busca local e global, uma inércia linear decrescente com a evolução do algoritmo tem uma boa capacidade de busca global no início e capacidade de busca local equivalente nas iterações finais. Desta forma, pode-se adotar o seguinte modelo de inércia:

$$w[t] = (w_{\text{inicial}} - w_{\text{final}}) \cdot \left(\frac{T_{\text{PSO}} - t}{T_{\text{PSO}}} \right)^{\delta} + w_{\text{final}} \quad (3.9)$$

onde w_{inicial} e w_{final} são a inércia inicial e final, respectivamente, $w_{\text{inicial}} > w_{\text{final}}$, T_{PSO} é o número máximo de iterações, e $\delta \in [0.6; 1.4]$ é o índice da adaptação não linear.

3.3 Meta-Heurísticas aplicadas ao método de Dinkelbach: DM-ACO e DM-PSO

A fim de resolver o problema de maximização da $\sum EE$, o método de Dinkelbach foi utilizado. Sabe-se que, quando se utiliza o método de Dinkelbach, é necessária a utilização de outra ferramenta de otimização para o *loop* interno. Por isso, os algoritmos $\text{ACO}_{\mathbb{R}}$ e PSO foram adaptados a fim de se encaixar ao *loop* interno do método de Dinkelbach apresentado no Algoritmo 1. Sabe-se que o chute inicial é fundamental para a qualidade da solução obtida por qualquer abordagem de otimização baseada em meta-heurísticas. Além disso, no Algoritmo 1, uma nova entrada \mathbf{p}_{t-1}^* é fornecida para o algoritmo do *loop* interno a cada iteração no

²Isto é análogo a idéia do fenômeno da inércia da mecânica clássica onde é mais difícil retirar objetos pesados (com grande inércia) das suas trajetórias de vôo do que objetos leves (pequena inércia)

loop externo. Uma vez que cada entrada não pode ser esquecida, cada instância da meta-heurística deve popular suas soluções iniciais de uma forma que não se perca a evolução alcançada nas iterações externas anteriores.

Portanto, o coeficiente de volatilidade $\alpha > 0$ foi adotado, objetivando controlar a geração das soluções iniciais das meta-heurísticas a cada nova instância (iteração externa do DM). A geração aleatória das soluções iniciais na t -ésima iteração externa é dada por:

$$s_l \sim \mathcal{U} [\mathbf{p}_{t-1}^* - \Psi; \mathbf{p}_{t-1}^* + \Psi], \quad l = 1, 2, \dots, \mathcal{P} \quad (3.10)$$

onde $\mathcal{P} = L$ caso a meta-heurística utilizada seja o ACO_ℝ, e $\mathcal{P} = M_{\text{pso}}$ caso seja o PSO; \mathbf{p}_{t-1}^* é o melhor vetor de potências encontrado na iteração externa anterior, e Ψ é o limite do intervalo de amostragem, dado por:

$$\Psi = e^{-\alpha \cdot t} \quad (3.11)$$

Assim, o processo de geração de soluções é sempre uma perturbação na melhor solução da iteração externa anterior, do método de Dinkelbach. Por exemplo, se $\mathbf{p}_{t-1}^* = \mathbf{p}_0^*$ na primeira iteração do algoritmo, a amostragem deve ser feita através de todo o domínio do problema $s_l \sim \mathcal{U}[p_{\min}, p_{\max}]$. Além disso, a perturbação vai ser mais estreita (em relação ao domínio) conforme o DM evolui, uma vez que o controle do intervalo de amostragem Ψ é feito por uma função exponencial negativa bivariada de α e t na equação (3.11). O procedimento para obter valores válidos do parâmetro α é apresentado na seção 4.3.1.

3.4 Benchmark ACO_ℝ

Nesta seção são apresentados os resultados de simulação objetivando avaliar a robustez e velocidade de convergência do ACO_ℝ a partir da calibragem de parâmetros de entrada do algoritmo. O desempenho do algoritmo implementado é verificado em termos do número de iterações e percentagem de sucesso na convergência.

Testes de funções *benchmark* identificadas na Tabela 3.1 foram realizados considerando o número de avaliações da função custo durante o processo de otimização. Para todos os resultados apresentados, as soluções iniciais foram forçadas a assumirem condições desfavoráveis, tendo em vista verificar a capacidade de escape de ótimos locais do ACO_ℝ.

Tabela 3.1: Funções de Benchmark utilizadas na Avaliação do ACO_ℝ.

ID	Função Custo
Easom	$f_{ES}(\mathbf{x}) = -\cos(x_1) \cos(x_2) \exp(-(x_1 - \pi)^2 - (x_2 - \pi)^2)$
Martin & Gaddy	$f_{MG}(\mathbf{x}) = (x_1 - x_2)^2 + \left(\frac{x_1 + x_2 - 10}{3}\right)^2$
Rosenbrok	$f_{Rn}(\mathbf{x}) = \sum_{i=1}^{n-1} 100(x_i^2 - x_i + 1)^2 + (x_i - 1)^2$
Zakharov	$f_{ZU}(\mathbf{x}) = \left(\sum_{j=1}^U x_j^2\right) + \left(\sum_{j=1}^U \frac{jx_j}{2}\right)^2 + \left(\sum_{j=1}^U \frac{jx_j}{2}\right)^4$
Griewangk	$f_{GRU}(\mathbf{x}) = \left(\frac{1}{10} + \left(\sum_{i=1}^U \frac{x_i^2}{4000} - \prod_{i=1}^U \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1\right)\right)^{-1}$
Goldstein & Price	$f_{GP}(\mathbf{x}) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 13x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \cdot [30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 - 48x_2 - 36x_1x_2 + 27x_2^2)]$

$\mathbf{x} = [x_1, x_2, \dots, x_U]$, onde U é a dimensão do problema

A Tabela 3.2 sumariza a capacidade do algoritmo ACO_ℝ em encontrar o ponto de ótimo global para diferentes funções com distintas dimensionalidades. Para todos os problemas, os resultados apresentados são a média em $\mathcal{T} = 10^3$ realizações. Nota-se que a diferença de desempenho em termos de percentagem de sucesso e/ou número de iterações para o mesmo problema (função) depende exclusivamente da natureza do problema, i.e., da quantidade de ótimos locais presentes na função e do intervalo de busca que contém a solução global. Como exemplo, a Fig. 3.2.a) indica que a função Easom apresenta apenas um ponto de ótimo local no intervalo considerado, portanto, a percentagem de sucesso é de 100% para a função Easom de dimensão $U = 2, 10$ e 20 ; enquanto que o gráfico da Fig. 3.2.b) indica que a função Griewangk apresenta uma enorme quantidade de ótimos locais no intervalo, dificultando, evidentemente, a convergência para o ótimo global. Duas outras funções benchmark e respectivas evoluções de convergência são apresentadas na Fig. 3.2.c) e 3.2.d).

A Tabela 3.2 indica ainda que para a função Griewangk de dimensão $n = 2$, a percentagem de sucesso do ACO_ℝ é de 100%. No entanto, quando $n = 10$, a esta percentagem é reduzida para 85% quando o intervalo de busca é $[\pm 5, 12]$. Somente quando o intervalo de busca é reduzido para $[\pm 3]$, a percentagem de sucesso obtida torna-se total.

Ademais, valores para o erro quadrático médio $MSE = \mathcal{T}^{-1} \sum_{t=1}^{\mathcal{T}} |f_t(\mathbf{x}) - f(\mathbf{x}^*)|^2$ para quatro funções *benchmark* versus o numero de iterações são ilustradas na Fig. 3.3; \mathcal{T} é o número de realizações adotado e $f(\mathbf{x}^*)$ o valor da função no ponto ótimo global. Com isso, pode-se observar que a taxa de decaimento do MSE em relação às iterações é inversamente proporcional à densidade de ótimos locais das respectivas funções de *benchmark* no espaço de busca considerado. É

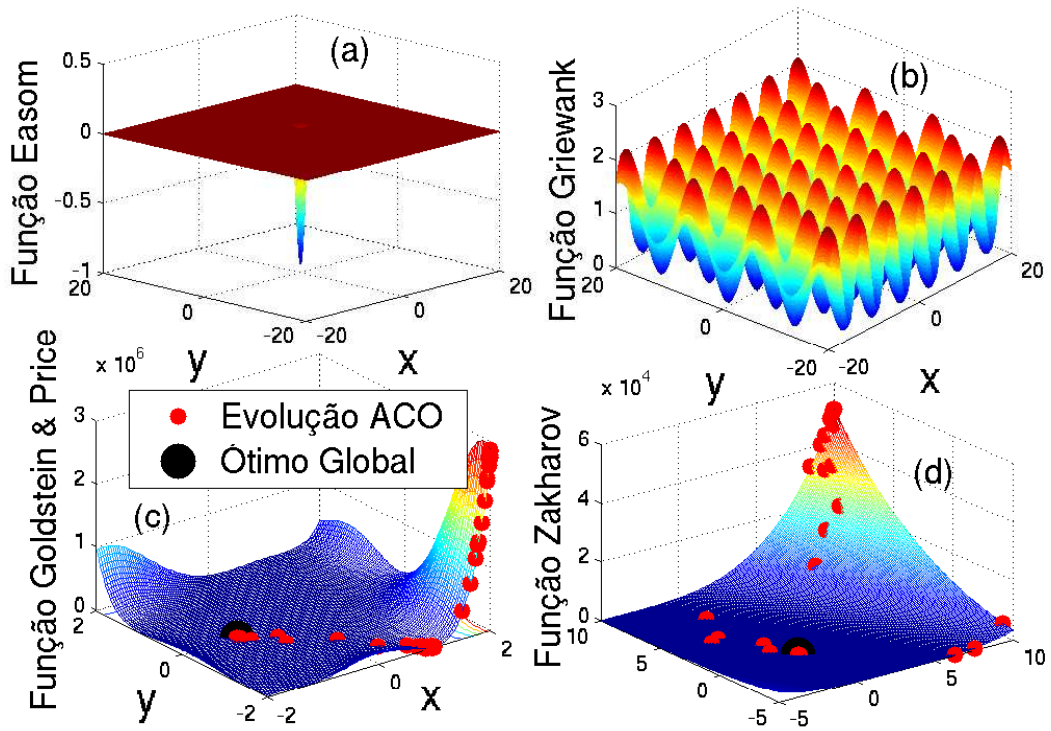


Figura 3.2: Função a) Easom; b) Griewangk; c) Godstein & Price; d) Rosenbrock

Tabela 3.2: Resultados de Convergência para o ACO_R em $\mathcal{T} = 10^3$

<i>Função</i>	<i>Itera</i>	<i>Dim</i>	<i>Intervalo</i>	<i>% Sucesso</i>
Easom	70	2	$[-100; 100]$	100
Griewangk	189	2	$[-5, 12; 5, 12]$	100
Goldstein Price	100	2	$[-2; 2]$	100
Rosenbrok	90	2	$[-5; 10]$	100
Sphere	26	6	$[-5, 12; 5, 12]$	100
Zakharov	40	2	$[-5; 10]$	100
Martin Gaddy	100	2	$[-20; 20]$	100
<i>Funções de Dimensão \mathbb{R}^U, com $U \geq 10$</i>				
Easom	341	10	$[-100; 100]$	100
Easom	344	20	$[-100; 100]$	100
Rosenbrok	517	10	$[-5; 10]$	100
Rosenbrok	578	20	$[-5; 10]$	100
Sphere	439	10	$[-5, 12; 5, 12]$	100
Sphere	941	20	$[-5, 12; 5, 12]$	100
Martin Gaddy	135	10	$[-20; 20]$	100
Martin Gaddy	148	20	$[-20; 20]$	100
Griewangk	2500	10	$[-5, 12; 5, 12]$	85
Griewangk	281	10	$[-3; 3]$	100

notável que a evolução do MSE para a função Easom é uma exceção à regra, dado que tal função possui apenas um ótimo local, que por sua vez é global. Apesar disso, a região plana desta função pode ser vista como uma região que contém infinitos ótimos locais, dado que todos os pontos nesta região possuem o mesmo valor, o que pode fazer com que o algoritmo meta-heurístico fique preso nessa região, ou apresente taxa de convergência muito baixa no início das iterações, principalmente se o espaço de busca mostrar-se muito extenso ao redor do ponto de ótimo global.




Figura 3.3: Evolução do MSE para as funções custo Sphere, Goldstein & Price, Griewangk e Easom.

3.4.1 Robustez *versus* Velocidade de Convergência

Funções multimodais constituem problemas complexos cuja obtenção do ótimo global pode tornar-se uma tarefa árdua para algoritmos de busca convencionais. Para algoritmos heurísticos, estas funções também constituem problemas complexos, principalmente se tais algoritmos não implementam estratégias elaboradas para escape de ótimos locais (mecanismos de diversidade). Desta forma, é necessário que os algoritmos tenham diversidade suficiente para não ficarem presos em ótimos locais, e ao mesmo tempo, que apresentem mecanismos de intensificação suficiente para evoluir caso encontrem a região próxima ao máximo global. Nitidamente, estes são objetivos contraditórios; de um lado, espera-se que o algoritmo heurístico venha a convergir o mais rápido possível, e de outro, que o mesmo não seja aprisionado em algum ótimo local. Mecanismos de

diversificação-intensificação incluem: a) divisão do algoritmo em uma parte inicial de diversificação, e a final de intensificação; b) balanceamento dinâmico e adaptativo de seu comportamento, através da adoção de parâmetros que enfatizem a intensificação (convergência rápida) no início do processo, intensificando posteriormente os mecanismos de diversificação (convergência lenta) ao final do processo de convergência.

O ACO_ℝ por sua vez, utiliza a técnica de balanceamento dinâmico. Sendo assim, quanto menor a taxa de aprendizado $\frac{1}{\xi}$, na eq. (3.5) e maior o tamanho do arquivo (L), mais robusto será o algoritmo, com conseqüente aumento do tempo convergência. Isso mostra que o tamanho do arquivo L , influencia diretamente na diversidade e no tempo de convergência do algoritmo, pois quanto mais soluções houver no arquivo, mais iterações serão necessárias para que o desvio padrão σ^i , eq. (3.5), em cada dimensão para todas as soluções ($\sigma^i = [\sigma_1^i, \dots, \sigma_l^i, \dots, \sigma_L^i]$) tenda a zero. Além disso, o ACO_ℝ possui o parâmetro q , também responsável pela diversidade do algoritmo.

Considerando a equação (3.2), quanto maior for o valor do parâmetro q , maior será o desvio padrão ($\sigma = qL$). Sabe-se que em uma variável aleatória Gaussiana, 68% das amostragens aparecerão dentro do intervalo $[\pm\sigma]$, ou seja, qk ; enquanto 98% das amostragens aparecerão dentro do intervalo $[\pm 2\sigma]$ [Sorensen 2006]. Desta forma, o parâmetro q é o responsável por influenciar o algoritmo em realizar a atualização de feromônio direcionada para o melhor resultado desde o começo do algoritmo (intensificação, *best-so-far*), ou para o melhor da iteração (diversificação, *iteration-best*). Ou seja, quando utiliza-se grandes valores de q , o algoritmo amostra o espaço de busca considerando um maior número de soluções possíveis. Assim, a busca é mais diversificada e o algoritmo torna-se mais robusto. Infelizmente, maior robustez significa maior tempo de convergência, portanto maior complexidade.

As figuras 3.4-a e 3.4-b apresentam valores de MSE e número de iterações em função dos parâmetros $q \in [0, 0001; 1]$ e $\xi \in [0, 7; 1, 5]$ para a função Sphere com 20 dimensões. Para isso, realizamos um processo iterativo baseado em [Filho, Souza e Abrão 2012], variando os valores de cada parâmetro enquanto os outros são fixados em uma configuração inicial. Neste caso, adotamos $q = 0, 1$, $\xi = 0, 9$, $m = 20$ e $L = 8$ como configuração inicial. Foram considerados passos de tamanho 0.01 para as figuras 3.4-a e 3.4-b. Para a figura 3.4-c, foram considerados passos de 0.0001. Na figura 3.4-a é possível verificar que a robustez do algoritmo (MSE) melhora conforme o parâmetro q tende a seu valor máximo. Por outro lado, é notável que o número de iterações aumenta exponencialmente em relação a

q . Portanto, é possível utilizar diferentes abordagens no processo de calibragem deste parâmetro: Pode-se encontrar um valor para o qual o algoritmo atinja um desempenho mínimo aceitável, reduzindo o tempo de convergência, ou adotar o valor máximo para q , e trabalhar com o $ACO_{\mathbb{R}}$ em sua forma mais poderosa, porém mais complexa.




Figura 3.4: MSE e número de iterações em função dos valores atribuídos aos parâmetro q (a) no primeiro passo de calibragem, e ξ (b) no primeiro e (c) no segundo passo de calibragem. Função: Sphere.

Na figura 3.4-b, é visível que a melhor configuração para o parâmetro ξ encontra-se ao redor de $\xi = 1,3$, além disso, nota-se que o número de iterações aumenta consideravelmente em relação à ξ . Vale ressaltar que o algoritmo perde desempenho quando $\xi > 1,3$ devido ao número máximo de iterações adotado $T = 1000$, dado que o algoritmo usaria muito mais iterações para esses valores (convergência lenta).

A figura 3.4-c mostra o segundo passo de calibragem do parâmetro ξ ao redor de $\xi = 1,3$, fixando $q = 1$. Nesta figura, fica evidente que o melhor valor de ξ para a função Sphere com 20 dimensões é $\xi = 1,26$.

4 Resultados Numéricos para Alocação de Recursos em Redes de Múltiplo Acesso

Neste capítulo, os resultados numéricos obtidos através da aplicação dos algoritmos meta-heurísticos, bem como da ferramenta CVX nos problemas de alocação de recursos discutidos no capítulo 2 serão apresentados.

As simulações de alocação de recursos em uma macro-célula no *downlink* do sistema MPG-DS/CDMA unicelular foram desenvolvidas na plataforma MatLab 7.0. Foi admitida uma célula retangular com uma ERB localizada no centro, e os usuários uniformemente distribuídos através da extensão da célula. Além disso, foi considerado que os terminais móveis experimentam canais com desvanecimento multi-percurso lento, e.x., a seguinte relação sempre é satisfeita:

$$T_{\text{slot}} < (\Delta t)_c \quad (4.1)$$

onde $T_{\text{slot}} = R_{\text{slot}}^{-1}$ é a duração do *slot* de tempo, R_{slot} é a taxa de atualização do vetor de potências de transmissão, e $(\Delta t)_c$ é o tempo de coerência do canal ¹. Isso faz parte do processo de estimativa da SNIR, ou seja, o canal será constante em cada janela de otimização, assumida aqui igual a $667\mu s$. Portanto, o algoritmo $\text{ACO}_{\mathbb{R}}$ deve convergir para a solução em cada intervalo de $667\mu s$.

A qualidade das soluções obtidas através dos algoritmos foi analisada a partir do erro quadrático médio normalizado (*Normalized Mean Squared Error* - NMSE), definido como:

$$\text{NMSE} = \mathbb{E} \left[\frac{\|\mathbf{p} - \mathbf{p}^*\|^2}{\|\mathbf{p}^*\|^2} \right] \quad (4.2)$$

onde \mathbf{p} é a solução encontrada através do algoritmo, \mathbf{p}^* a solução analítica (ótima) e \mathbb{E} o operador matemático da esperança.

¹Corresponde ao intervalo de tempo em que as características do canal não sofrem variações expressivas

4.1 Alocação de Potência Mínima em Redes MPG-DS/CDMA

O objetivo do problema de alocação de potência mínima, como visto no capítulo 2, é colocar o sistema no modo de operação em que todos os terminais móveis, bem como as estações rádio-base, utilizem a menor quantidade de energia possível, em termos de potência de transmissão, a fim de operar com seus requisitos de QoS satisfeitos.

Os parâmetros de sistema utilizados para as simulações nesta seção, são apresentados na Tabela 4.1:

Tabela 4.1: Parâmetros do Sistema DS/CDMA Macro-Celular Multi-Taxa e de Canal

Parâmetros	Valores Adotados
<i>Sistema DS/CDMA para Alocação de Potência e Taxa</i>	
Potência de Ruído	$P_n = -63$ [dBm]
Largura de Banda CDMA	$r_c = 5$ [MHz]
Potência Máxima por Usuário	$p_{\max} = 1$ [W]
# Usuários por classe	$\{U^{\text{VOZ}}; U^{\text{VÍDEO}}; U^{\text{DADOS}}\}$
$U = [5, 10, 20]$:	$\{[3; 1; 1], [5; 3; 2], [12; 5; 3]\}$
<i>Desvanecimento de Canal</i>	
Perda de Percurso	$\propto d^{-2}$
Sombreamento	Log-normal, $\sigma^2 = 6$ dB
Desvanecimento Multi-Percurso	Rayleigh
Seletividade no tempo	lenta
<i>Características de usuário e QoS</i>	
Classes de Serviço	[VOZ; VÍDEO; DADOS]
Taxas de Usuário ($\frac{r_c}{F_i}$)	$r_{i,\min} = [\frac{r_c}{256}; \frac{r_c}{16}; \frac{r_c}{8}]$ [bps]
BER máxima tolerável, $\text{BER}_{\text{serv}}^{\max}$	$[5 \times 10^{-3}; 5 \times 10^{-5}; 5 \times 10^{-8}]$
Taxa de informação base	$r = 19.5$ [kbps]

O comportamento típico de convergência para este problema é apresentado na figura 4.1. Nesta figura, a alocação de potência para $U = 5$ usuários (sistema levemente carregado) é realizada pelos algoritmos a) $\text{ACO}_{\mathbb{R}}$ [Marques et al. 2012] e b) PSO [Abrão et al. 2011]. É fácil verificar a convergência suave do algoritmo $\text{ACO}_{\mathbb{R}}$ em relação à solução ótima (obtida a partir do sistema linear na Eq. (2.22)), em contraste à convergência oscilante do PSO. Esta diferença acontece devido às características de convergência de cada algoritmo, uma vez que o PSO é nitidamente menos complexo (computacionalmente) que o $\text{ACO}_{\mathbb{R}}$, apresentando estratégias mais singelas para o escape de ótimos locais. Além disso, para o problema de alocação de potência mínima com $U = 5$ usuários, o $\text{ACO}_{\mathbb{R}}$ foi capaz de convergir depois de ≈ 250 iterações, contra ≈ 450 iterações do PSO.

Ainda no contexto do problema de alocação de potência mínima, a Fig. 4.2 apresenta o NMSE em função do número de iterações do algoritmo para diferentes




Figura 4.1: Alocação de potência mínima (Eq. (2.23)) para $U = 5$ usuários. a) ACO_R [Marques et al. 2012]; b) PSO [Abrão et al. 2011].

combinações dos parâmetros de entrada.




Figura 4.2: NMSE para diferentes combinações dos parâmetros do ACO_R com $U = 20$ usuários. Para todas as configurações, foi utilizado $L = 25$, $M_{ACO} = 35$

Nota-se que o tamanho da população M_{ACO} e o tamanho do arquivo de solu-

ções L ($M_{\text{ACO}}, L \in \mathbb{N}$), ambos com valores de entrada comuns a todas as configurações de $\{q, \xi\}$, foram escolhidos com base na dimensionalidade do problema. Vale ressaltar que o problema de alocação de potência em (2.23) não é convexo, portanto, os parâmetros M_{ACO} e L assumem valores relativamente altos em relação às dimensões do problema. Isso significa que o $\text{ACO}_{\mathbb{R}}$ é capaz de resolver o problema não convexo de alocação de potência mínima em sistemas MPG-DS/CDMA, porém com cargas de parâmetros de entrada relativamente altas.

Neste ponto, a calibragem de parâmetros foi realizada de forma não exaustiva, objetivando encontrar valores aceitáveis para os parâmetros $\{q, L\}$. Uma vez que os parâmetros L e M_{ACO} estão diretamente relacionados à complexidade computacional do algoritmo, encontrar os menores valores factíveis para eles é de grande interesse. Portanto, os parâmetros M_{ACO} e L foram fixados nos menores valores possíveis e então, os melhores valores para q e ξ foram obtidos a partir de uma busca não exaustiva. Desta forma, baseado nos resultados de NMSE *versus* velocidade de convergência obtidos na figura 4.2, os valores sub-ótimos para os parâmetros q e ξ do $\text{ACO}_{\mathbb{R}}$ foram encontrados de forma não exaustiva, e apresentados na Tabela 4.2.

Tabela 4.2: Parâmetros de entrada sub-ótimos obtidos para o $\text{ACO}_{\mathbb{R}}$ na resolução do problema da Eq. (2.23)

U (Usuários)	5	10	20
q	0.61	0.40	0.40
ξ	1.00	0.82	0.75
M_{ACO}	7	15	35
L	8	4	25

4.1.1 Desempenho do $\text{ACO}_{\mathbb{R}} \times \text{PSO}$


O principal objetivo desta análise é verificar o desempenho das duas meta-heurísticas abordadas neste trabalho, quando aplicadas a um problema não convexo, como por exemplo, o de alocação de potência mínima apresentado na Eq. (2.23). As simulações foram realizadas em diferentes carregamentos do sistema MPG-DS/CDMA, de acordo com os parâmetros sub-ótimos obtidos nesta seção para o $\text{ACO}_{\mathbb{R}}$, e com os parâmetros também sub-ótimos obtidos em [Abrão et al. 2011] para o mesmo problema, utilizando o PSO. Os valores sub-ótimos para os parâmetros ϕ_1, ϕ_2 e ω do PSO foram encontrados de forma não exaustiva, e apresentados na Tabela 4.3.

A Figura 4.3 apresenta a evolução do NMSE para o problema de alocação de potência mínima com $U = 5, 10$ e 20 usuários, respectivamente, para os algoritmos

Tabela 4.3: Parâmetros de entrada sub-ótimos obtidos em [Abrão et al. 2011] para o PSO na resolução do problema da Eq. (2.23)

U (Usuários)	5	10	20
ϕ_1	1	1	1
ϕ_2	2	2	2
M_{PSO}	7	100	200
ω	1.5	2	2.5

ACO_R e PSO. Claramente, o NMSE $\approx 10^{-12}, 10^{-10}, 10^{-2}$ obtido pelo ACO_R é muito menor que os valores obtidos pelo PSO (NMSE $\approx 10^{-8}, 10^{-8}$ e 10^{-1}). Além disso, para o PSO convergir, foi necessário aumentar o número máximo de iterações para $T = 2000$ quando $U = 10$ e $T = 5000$ quando $U = 20$, em conjunto com uma sobrecarga no tamanho da população para $M_{\text{PSO}} = 10 \cdot U$ quando $U \geq 10$. Isso significa que a menor complexidade computacional do PSO teve de ser compensada no tamanho da população e no número de iterações para contornar os vários problemas de convergência ao resolver um problema não convexo. A robustez obtida mostrou que o ACO_R obteve quase sucesso total de convergência nos carregamentos de sistema considerados, enquanto o PSO não foi capaz de convergir para soluções aceitáveis em 1000 iterações, para sistemas com mais de $U = 10$ usuários.

**Figura 4.3:** NMSE alcançado pelos algoritmos RA-ACO e RA-PSO [Abrão et al. 2011], para $U = 5, 10$ e 20 usuários.

A Tabela 4.4 contém a robustez para ambos os algoritmos, ex. a porcentagem

de execuções em que o algoritmo obteve $\text{NMSE} \leq 10^{-2}$, mostrando claramente a superioridade do $\text{ACO}_{\mathbb{R}}$. Apesar disso, a superioridade do $\text{ACO}_{\mathbb{R}}$ em termos de robustez já era esperada, dada sua maior complexidade computacional. Ainda que o $\text{ACO}_{\mathbb{R}}$ tenha obtido melhores resultados em termos de robustez utilizando menos iterações que o PSO, não é possível concluir-se que o PSO não é competitivo para a resolução do problema de alocação de potência mínima sem uma análise da sua complexidade computacional. Desta forma, este aspecto será abordado na Seção 4.1.2.

Tabela 4.4: Robustez dos algoritmos RA-ACO e RA-PSO para o problema de controle de potência da Eq.(2.23) em 500 realizações.

# Usuários U	Robustez, \mathcal{R}	
	RA-ACO	RA-PSO
5	100 %	100 %
10	100 %	100 %
20	73 %	38 %

4.1.2 Complexidade Computacional

Nesta seção, uma análise da complexidade computacional das meta-heurísticas utilizadas através do tempo de execução obtido foi realizada. A Fig. 4.4 apresenta o tempo de execução obtido em função do número de usuários para os algoritmos $\text{ACO}_{\mathbb{R}}$ e PSO. É notável o aumento do tempo de execução para o PSO quando $U \geq 10$ usuários, devido ao maior número de iterações em conjunto com a sobrecarga de população utilizada.

Os resultados numéricos obtidos nesta seção mostraram que o $\text{ACO}_{\mathbb{R}}$ é suficientemente robusto para resolver o problema de alocação de potência mínima em redes MPG-DS/CDMA. De fato, o desempenho do algoritmo $\text{ACO}_{\mathbb{R}}$ superou a do PSO em relação à robustez (Tabela 4.4) em 35% nos sistemas com $U = 20$ usuários. Em relação à qualidade de solução obtida, o $\text{ACO}_{\mathbb{R}}$ obteve resultados mais satisfatórios que o PSO, o que já era esperado dada sua maior complexidade computacional. Apesar disso, a análise do tempo de execução obtido pelas meta-heurísticas mostrou que o maior número de iterações em conjunto com a sobrecarga de população utilizada pelo PSO a fim de obter convergência quando $U \geq 10$ usuários, tornou o RA-PSO uma abordagem mais complexa.




Figura 4.4: Tempo de execução para os algoritmos RA-ACO e RA-PSO [Abrão et al. 2011], com $U = 5, 10$ e 20 usuários.

4.2 Maximização do Fluxo de Informação do Sistema (WTM)

Nesta seção, o problema WTM será investigado através dos algoritmos $ACO_{\mathbb{R}}$ e PSO. Resultados incluindo taxa de informação, potência de transmissão e tempo de execução são comparados com a ferramenta CVX [CVX Research, Inc. 2012]. Por fim, será apresentada uma análise do número de operações de ponto flutuante utilizadas para cada uma das meta-heurísticas na resolução do problema.

Em todos os resultados desta seção, os mesmos coeficientes de canal Rayleigh estáticos foram adotados para ambas as abordagens. Tipicamente, as perdas de energia devido ao canal em dB para um sistema com U usuários resultam em uma matriz de perda de potências relativa para os sinais interferentes que varia de $[8; 40]$ dB, representando alta interferência em relação aos *links* com linha de visada; além disso, altos níveis de correlação cruzada entre as sequências de espalhamento foram adotados. Finalmente, para o problema WTM, os parâmetros de entrada das meta-heurísticas foram calibrados de forma não exaustiva. A tabela 4.5 apresenta os parâmetros e as configurações de sistema, canal e dos algoritmos utilizados neste problema.

A Figura 4.5 apresenta a evolução da taxa de informação total do sistema, e da potência de transmissão total consumida como uma função das iterações

Tabela 4.5: Sistema DS/CDMA macro-celular multi-taxa, parâmetros de canal e do algoritmo ACO_ℝ

Parâmetros	Valores Adotados
<i>Sistema DS/CDMA de Alocação de Potência e Taxa</i>	
Potência de Ruído	$P_n = -63$ [dBm]
Taxa de Chip	$r_c = 5 \times 10^6$
Potência máxima por usuário	$p_{\max} = 2$ [W]
Duração do <i>time slot</i>	$T_{\text{slot}} = 666.7 \mu\text{s}$
# terminais móveis	$U \in \{5; 10; 20; 30\}$ users
# Usuários por classe	$\{U^{\text{VOZ}}; U^{\text{VÍDEO}}; U^{\text{DADOS}}\}$
$U = [12, 20, 30]$:	$\{6; 4; 2\}, \{9; 6; 5\}, \{16; 9; 5\}$
# Estações rádio base	BS = 1
Geometria da Célula	Retangular, $x_{\text{cell}} = y_{\text{cell}} = 5$ Km
Distribuição dos terminais móveis	$\sim \mathcal{U}[x_{\text{cell}}, y_{\text{cell}}]$
<i>Tipo de desvanecimento de canal</i>	
Perda de Percurso	$\propto d^{-2}$
Sombreamento	Log-normal, $\sigma^2 = 6$ dB
Desvanecimento Multi-percurso	Rayleigh
Seletividade no tempo	lenta
<i>Características de usuário e QoS</i>	
Classes de Serviço	[VOZ; VÍDEO; DADOS]
Taxas mínima de serviço ($\frac{r_c}{F_i}$)	$r_{i,\min} = [\frac{r_c}{256}; \frac{r_c}{16}; \frac{r_c}{8}]$ [bps]
BER máxima tolerável, $\text{BER}_{\text{serv}}^{\max}$	$[5 \cdot 10^{-3}; 5 \cdot 10^{-5}; 5 \cdot 10^{-8}]$
Taxa de informação base	$r = 19.5$ [kbps]
<i>Algoritmo RA-ACO</i>	
Tamanho do arquivo	$L \in [8, 25]$;
Fator de diversidade	$q \in [0, 1]$;
Taxa de evaporação de feromônio	$\xi \in [0, 1]$;
Tamanho da população	$M_{\text{ACO}} \in [12, 18, 35]$;
Max. de iterações #	$T = 1000$
<i>Algoritmo RA-PSO</i>	
Tamanho da População	$M_{\text{PSO}} \in [12, 25, 10 \cdot U]$;
Peso da Inércia	$\omega \in [2.5, 3, 3.3]$;
Coefficiente de Aceleração Local	$\phi_1 = 2$;
Coefficiente de Aceleração Global	$\phi_2 = 2$;
Max. Iterações #	$T = 5000$

dos algoritmos $\text{ACO}_{\mathbb{R}}$ e PSO. A solução ótima (OPT) foi obtida a partir do CVX [CVX Research, Inc. 2012]. É possível verificar a evolução monotônica das meta-heurísticas para a ΣR , enquanto a evolução de ΣP não é monotônica, uma vez que o objetivo da função custo é maximizar o fluxo total de informação do sistema. Além disso, o nível de ΣP é menor para $U = 30$ do que $U = 12$ e $U = 20$ devido à duas razões: primeiramente, o nível médio de potência de transmissão por classe de serviço diminui conforme o carregamento do sistema aumenta, devido à necessidade de garantir QoS à todos os usuários; em segundo lugar, o nível total de potência depende do número de usuários em cada classe de serviço, uma vez que os usuários das classes VÍDEO e DADOS utilizam níveis de potência de transmissão muito mais altos do que os usuários de VOZ, devido aos maiores níveis de SNIR que necessitam satisfazer. O nível médio de potência por tipo de serviço pode ser visto na Tabela 4.6, juntamente com o número de usuários em cada classe de serviço para cada carregamento de sistema avaliado.




Figura 4.5: Evolução de ΣR e ΣP em função das iterações do $\text{ACO}_{\mathbb{R}}$.

Quanto à diferença de desempenho entre as meta-heurísticas, pode ser visto que a convergência do PSO é mais rápida (inicialmente) em relação ao $\text{ACO}_{\mathbb{R}}$ quando $U \leq 20$ usuários. Apesar disso, sabe-se que no contexto das meta-heurísticas, algoritmos de convergência mais rápida tendem a obter menor qualidade de aproximação. A maior velocidade de convergência do PSO acontece devido ao fato de que o PSO é um algoritmo mais simples que o $\text{ACO}_{\mathbb{R}}$. Apesar disso, o $\text{ACO}_{\mathbb{R}}$ é muito mais preciso em termos de qualidade de aproximação; tal diferença evidencia-se quando a dimensão do problema cresce.

Ademais, quando a dimensão do problema aumenta ($U \geq 30$ usuários), ambas as meta-heurísticas não são capazes de convergir completamente em $T \leq 1000$ iterações; por exemplo, na Fig. 4.5, apesar de $\sum R^{\text{aco}}$ alcançar marginalmente $\sum R^{\text{cvx}}$, $\forall U \in [12; 30]$ usuários, $\sum P^{\text{aco}} > \sum P^{\text{cvx}}$ para $U = 30$ usuários. Além disso, o PSO utilizou $T = 5000$ iterações para o caso com $U = 30$ usuários, em conjunto com uma sobrecarga no tamanho da população ($10 \cdot U$) a fim de atingir valores aceitáveis de taxa de informação e potência total de transmissão, o que torna nítida a simplicidade do algoritmo. No entanto, mesmo utilizando cinco vezes mais iterações, não é possível concluir-se que o PSO não é competitivo para a resolução deste problema de otimização se não analisarmos sua complexidade computacional. Desta forma, este importante aspecto será discutido na Sec. 4.2.1.

Tabela 4.6: Nível médio de potência de transmissão obtido por classe de usuário.

U	Usuários - Classe	Potência Média [W]
12	6 - VOZ	0,0791
	4 - VÍDEO	1,3730
	2 - DADOS	1,9791
20	9 - VOZ	0,1900
	6 - VÍDEO	1,2423
	5 - DADOS	1,5619
30	16 - VOZ	0,0200
	9 - VÍDEO	0,2022
	5 - DADOS	1,0438

As Figs. 4.6 e 4.7 apresentam as taxas individuais e as potências de transmissão para cada usuário, respectivamente, em um sistema com $U = 30$ usuários. É possível verificar que a diferença entre os resultados dos três algoritmos se torna mais evidente em relação aos níveis de potência individuais. Além disso, a partir da Fig. 4.5, está claro que para $U = 30$ usuários, as meta-heurísticas atingem soluções que gastam mais potência para um fluxo de informação total do sistema marginalmente menor que a solução obtida pelo CVX, ex. para $U = 30$ usuários, as meta-heurísticas não são capazes de convergir completamente para o ótimo global do problema com menos de 1000 iterações. Uma vez que a taxa de informação atingível é uma função monotonicamente crescente da potência de transmissão, pode-se dizer que a solução trivial do problema de maximização do fluxo de informação total do sistema é colocar todos os usuários para transmitir com a potência máxima permitida no sistema. Apesar disso, o nível de interferência de múltiplo acesso (*Multiple Access Interference* - MAI) seria muito alto neste caso, e o somatório de taxas atingível neste caso é sempre menor que o ótimo.

Portanto, sob a perspectiva do problema WTM apresentada na Equação (2.26), o procedimento de otimização através das meta-heurísticas aqui propostas é capaz de encontrar os melhores fluxos de informação para o sistema e manter os níveis de potência de transmissão em patamares factíveis ao mesmo tempo.

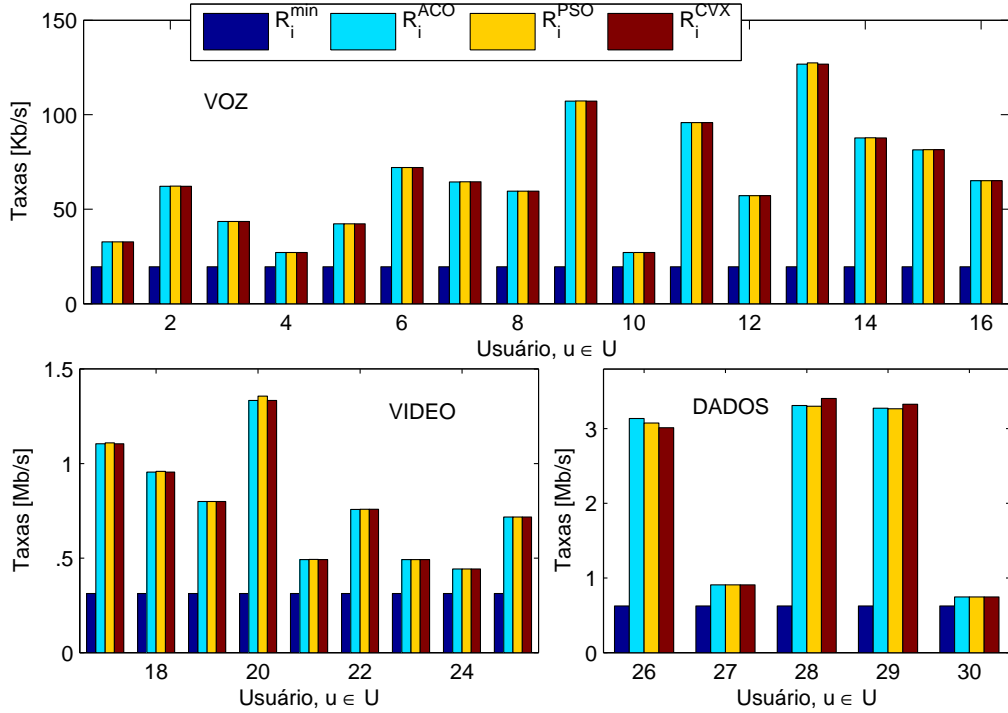


Figura 4.6: Taxas mínimas (QoS) e ótimas ($\max \sum R$) depois da convergência dos algoritmos $\text{ACO}_{\mathbb{R}}$ e CvX para o problema WTM com $U = 30$ usuários.

A evolução das meta-heurísticas através da convergência dos níveis individuais de potência e taxa de informação pode ser vista nas figuras 4.8 e 4.9, respectivamente. De fato, a abordagem heurística proposta é capaz de encontrar taxas de informação viáveis sob níveis de potência factíveis devido ao fato de que a taxa de informação para os usuários de voz diminui conforme o algoritmo evolui, uma vez que eles possuem a menor contribuição em relação à eficiência espectral (SE) total do sistema em relação às outras classes (Eq. (2.29)). Portanto, o valor da função custo diminui quando o nível de potência dos usuários de VOZ vai além de ≈ 200 [mW]. Por outro lado, as taxas de informação individuais aumentam para os usuários de VÍDEO e DADOS, dado que eles contribuem muito mais à SE do que os usuários de VOZ. Esta característica de convergência ocorre devido à abordagem adotada para a formulação dos pesos de cada serviço neste trabalho, Eq. (2.29). Adicionalmente, este comportamento pode ser visto para a convergência dos níveis de potência na Figura 4.7.

A figura 4.10 apresenta a evolução do NMSE em função do número de iterações para sistemas com $U \in [12; 20; 30]$ usuários. Está claro que o $\text{ACO}_{\mathbb{R}}$ converge




Figura 4.7: Níveis ótimos de potência ($\max \sum R$) depois da convergência dos algoritmos $\text{ACO}_{\mathbb{R}}$ e CvX para o problema WTM com $U = 30$ usuários.

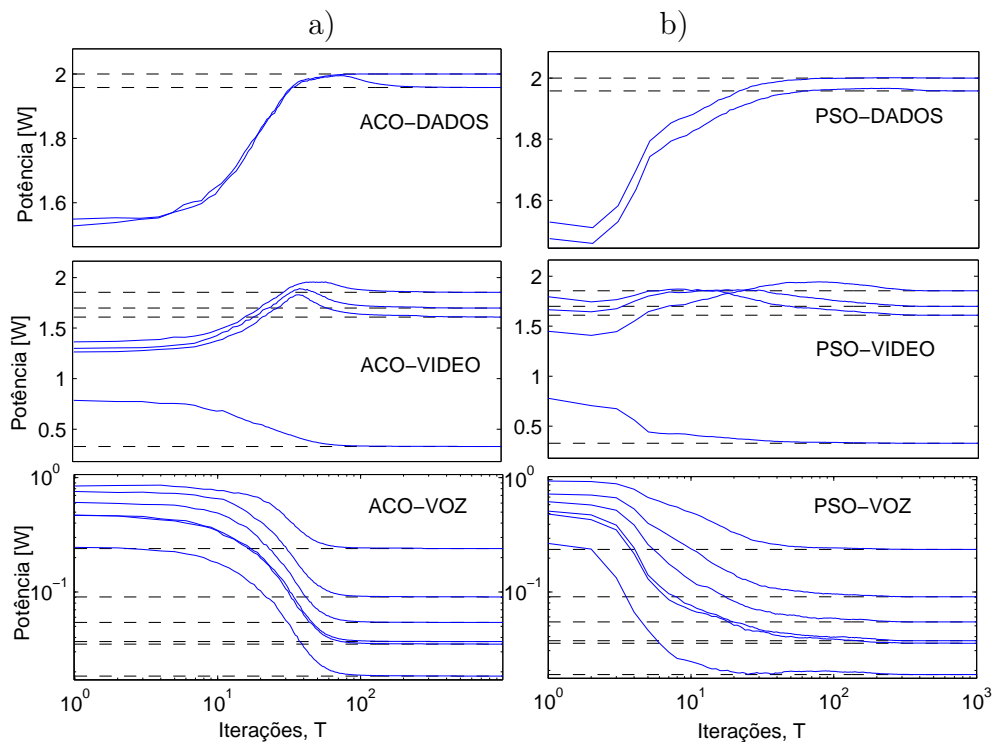


Figura 4.8: Convergência dos níveis de potência individuais para o $\text{ACO}_{\mathbb{R}}$ a) e o PSO b) em um sistema com $U = 12$ usuários. Os níveis ótimos foram obtidos a partir do CvX.

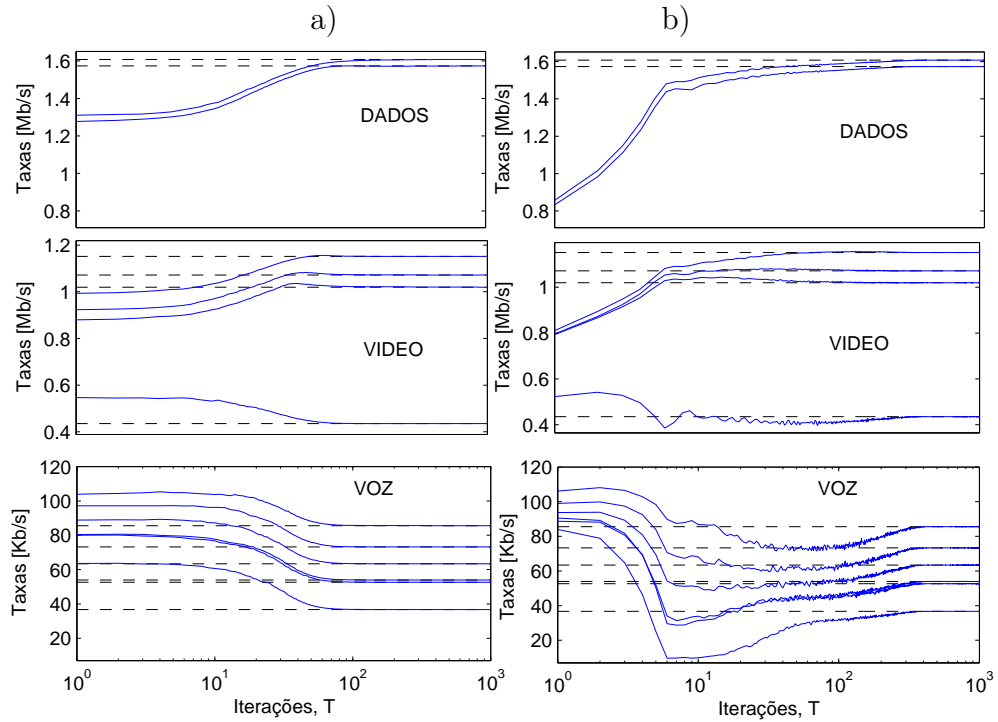


Figura 4.9: Convergência das taxas de informações individuais para o $\text{ACO}_{\mathbb{R}}$ a) e o PSO b) em um sistema com $U = 12$ usuários. Os níveis ótimos foram obtidos a partir do CvX.

superlinearmente em direção ao vetor ótimo de potências de transmissão \mathbf{p}^* . Além disso, o algoritmo heurístico é capaz de encontrar boas soluções aproximadamente ótimas ($\text{NMSE} < 10^{-3}$) para sistemas com $U \leq 20$ usuários, em um máximo de $T = 1000$ iterações, enquanto para $U = 30$ usuários, a convergência acontece vagarosamente, apesar de aceitável, com $\text{NMSE} \approx 2 \cdot 10^{-2}$. Quanto ao PSO, pode ser visto que ele converge normalmente quando $U \leq 20$ usuários. Além disso, a partir do NMSE fica claro que a velocidade de convergência do PSO é maior que a do $\text{ACO}_{\mathbb{R}}$ para esta faixa de número de usuários. Não obstante, pode ser visto também que o $\text{ACO}_{\mathbb{R}}$ sempre obtém uma solução mais próxima da ótima que o PSO. Ademais, quando $U = 30$ usuários, o PSO precisa de cinco vezes mais iterações em relação às outras configurações, a fim de atingir um patamar de convergência aceitável ($\text{NMSE} < 10^{-1}$). Além do maior número de iterações, foi realizada uma sobrecarga no tamanho da população ($10 \cdot U$), a fim de obter a convergência.

A Figura 4.11 apresenta o valor da função custo em função da alocação de potência de transmissão para a) o primeiro usuário, p_1 e b) o último usuário, p_{30} , enquanto os outros usuários mantêm individualmente seus valores ótimos de potência alocada dados pelas respectivas meta-heurísticas no final do processo de otimização, ex. depois de $T = 1000$ iterações. A evolução do algoritmo $\text{ACO}_{\mathbb{R}}$ em direção ao valor ótimo da função custo através das $T = 1000$ iterações é




Figura 4.10: Evolução do NMSE para o $ACO_{\mathbb{R}}$ em relação ao vetor de potências de transmissão \mathbf{p}^* para $U = [12; 20; 30]$ usuários.

visível. Por outro lado, pode-se verificar o quão lenta é a convergência do PSO no sistema com $U=30$ usuários, dado o número de iterações utilizados, a sobrecarga de população atribuída, bem como os pequenos passos de evolução a cada iteração. De fato, na Figura 4.11.a (um usuário de VOZ), pode ser visto que o valor da função custo diminui quando a potência de transmissão alocada vai além de ≈ 10 [mW]. Adicionalmente, quando a potência de transmissão é menor que 10[mW], o valor da função custo varia marginalmente, o que mostra que os usuários de VOZ não contribuem consideravelmente para a eficiência espectral total do sistema ($\sum SE$). Por outro lado, a Figura 4.11.b mostra que para os usuários de DADOS (ou VÍDEO), a contribuição é mais efetiva melhorando consideravelmente a $\sum SE$, uma vez que o valor da função custo é muito menor quando os usuários pertencentes a esta classe de serviço não estão operando em seus níveis de potência ótimos.

4.2.1 Complexidade Computacional

Uma análise da complexidade computacional através do tempo de execução e do número de operações de ponto flutuante (FLOPS) foi realizada para os algoritmos utilizados no problema WTM. Sabe-se, a partir da literatura, que a complexidade computacional das meta-heurísticas ($ACO_{\mathbb{R}}$ e PSO) é consideravelmente menor que a do CVX (determinístico), fazendo com que elas se tornem

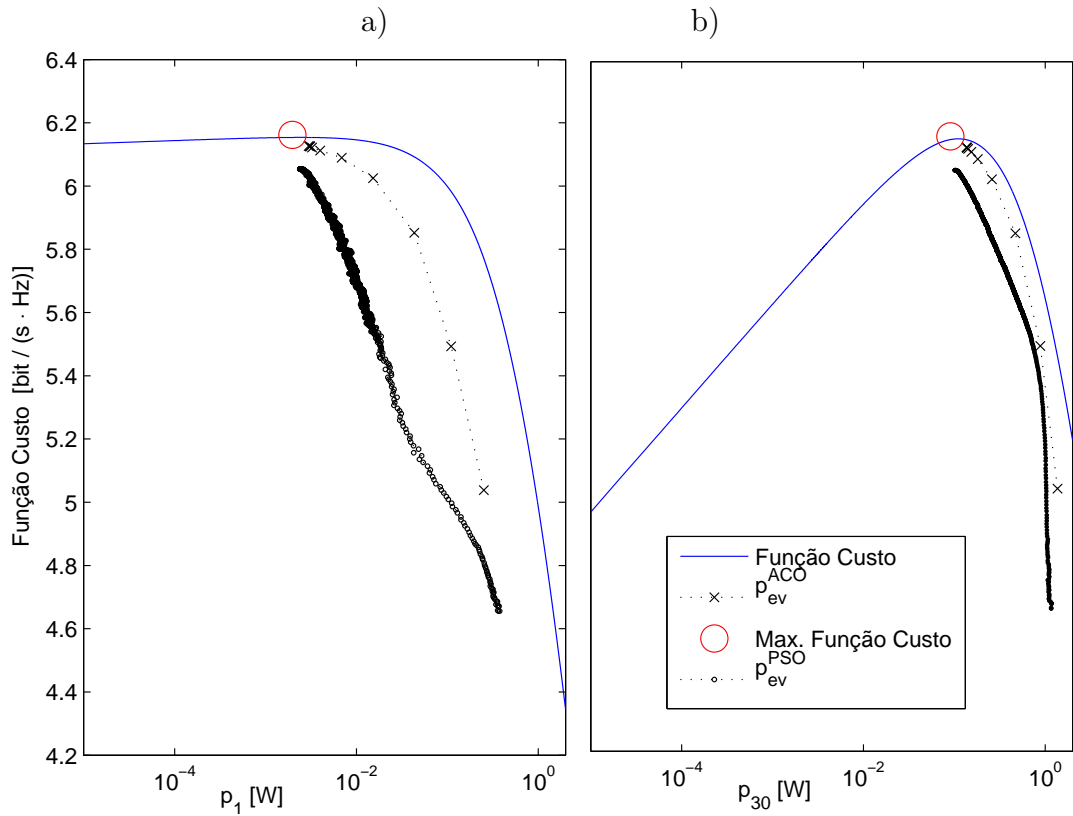


Figura 4.11: Comportamento da função custo para o vetor ótimo de potências de transmissão \mathbf{p}^* , exceto para as potências a) p_1 e b) p_{30} , em um sistema com $U = 30$ usuários.

abordagens competitivas caso consideremos a potência de circuitaria em conjunto com a potência de transmissão. Portanto, a eficiência energética do sistema pode melhorar, mesmo sob a perspectiva de maximização da eficiência espectral sugerida nesta seção.

Além disso, visando propor um método de otimização eficiente em relação ao compromisso qualidade de solução *versus* complexidade computacional, uma análise de desempenho em relação à robustez e tempo de execução dos algoritmos é apresentada a seguir.

O tempo de execução para os algoritmos $ACO_{\mathbb{R}}$, PSO e CvX em função do número de usuários no sistema é apresentado na Fig. 4.12. Está claro que a complexidade de ambas as meta-heurísticas é consideravelmente menor que a do CvX, ao custo de uma menor qualidade de convergência quando o carregamento do sistema aumenta ($U \geq 30$ usuários). Quanto ao PSO, pode ser visto que seu tempo de execução é menor que o do $ACO_{\mathbb{R}}$ quando $U \leq 20$ usuários, apesar disso, seu tempo de execução aumenta proibitivamente (para uma meta-heurística) quando $U = 30$ usuários, devido à sobrecarga da população e ao aumento do número de iterações utilizadas. Possivelmente uma otimização adicional dos parâmetros de entrada do PSO deveria ser obtida tendo em vista a operação eficiente do

algoritmo na condição de um elevado número de usuários.

A Tabela 4.7 mostra as porcentagens de $\sum P$, $\sum R$ e tempo de execução para o $\text{ACO}_{\mathbb{R}}$ e o PSO em relação ao CvX para os três carregamentos de sistema considerados. É notável que para $U = 30$ usuários, o $\text{ACO}_{\mathbb{R}}$ é capaz de atingir 99,5% do fluxo de informação ótimo, gastando 26% mais energia, com $\approx 91\%$ menos tempo de execução em relação ao CvX. Portanto, se considerarmos a potência de circuitaria, a solução obtida pelo $\text{ACO}_{\mathbb{R}}$ está muito próxima da eficiência espectral ótima (0,5% menor, no pior caso); por outro lado, a abordagem meta-heurística pode atingir valores significantes de EE mesmo sob a perspectiva do WTM, devido aos baixos níveis de potência de circuitaria utilizados na execução do processo de otimização. Finalmente, pode ser visto que o PSO torna-se custoso quando $U = 30$ usuários, pois apesar de obter uma aproximação aceitável da solução ótima (98,3% $\sum R$), é quase oito vezes mais lento que o $\text{ACO}_{\mathbb{R}}$ para obter a solução.




Figura 4.12: Tempo de execução dos algoritmos em função do número de usuários U para o problema WTM.

Além disso, a partir da tabela 4.7 é notável que a diferença em relação ao tempo de execução entre as duas abordagens aumenta de forma diretamente proporcional ao número de usuários no sistema.

Finalmente, a fim de validar o estudo em relação à complexidade das meta-heurísticas, o número de operações de ponto flutuante (FLOPs) foi considerado. Neste trabalho, as operações de multiplicação, adição, subtração e divisão foram

Tabela 4.7: Porcentagens obtidas para as métricas $\sum P$, $\sum R$ e Tempo de Execução para os algoritmos $\text{ACO}_{\mathbb{R}}$ e PSO em relação ao algoritmo determinístico CvX.

U	$\sum R$ [%]		$\sum P$ [%]		Tempo de Execução [%]	
	$\text{ACO}_{\mathbb{R}}$	PSO	$\text{ACO}_{\mathbb{R}}$	PSO	$\text{ACO}_{\mathbb{R}}$	PSO
12	100	100	100	100	22	10,20
20	100	100	100	100	12,12	10,48
30	99,5	98,3	126	136,2	8,91	71,71

consideradas como tendo custo computacional equivalente. Além disso, o custo computacional das operações matriciais (ordenação, transposição, comparação, troca, geração de números aleatórios) são considerados proporcionais ao tamanho do problema, por exemplo, o número de elementos de um vetor ou matriz. A Tabela 4.8 apresenta a complexidade computacional das meta-heurísticas $\text{ACO}_{\mathbb{R}}$ e PSO em função do número de iterações utilizados, da dimensionalidade do problema e dos respectivos parâmetros de entrada. A partir disso, fica nítida a diferença de complexidade computacional entre o $\text{ACO}_{\mathbb{R}}$ e o PSO. No entanto, a menor complexidade computacional do PSO fez com que fosse necessário um maior número de iterações em conjunto com uma sobrecarga no tamanho da população, fazendo-o uma abordagem mais cara que o $\text{ACO}_{\mathbb{R}}$. O número de operações de ponto flutuante obtido em função do número de usuários do sistema pode ser visto na Fig. 4.13. Nitidamente, o número de FLOPs confirma os resultados obtidos a partir da análise do tempo de execução dos algoritmos, evidenciando-se a maior ordem na escala de crescimento computacional do PSO em relação à dimensão do problema (número de usuários); por exemplo, o PSO atinge a ordem de $\approx 10\times$ maior que aquela utilizada pelo $\text{ACO}_{\mathbb{R}}$ quando $U = 30$ usuários. Evidentemente, esta diferença cresce com a dimensão do problema.

Tabela 4.8: Número de operações para os algoritmos $\text{ACO}_{\mathbb{R}}$ e PSO.

Número de Operações
$T_{\text{ACO}_{\mathbb{R}}} \cdot \{M_{\text{ACO}_{\mathbb{R}}}(8 + 8U + 5LU + 3L) + U[L(U + 12) + 6] + L(5 + \log L)\}$
$T_{\text{PSO}} \cdot \{U[M_{\text{PSO}}(U + 34) + 8] + M_{\text{PSO}}(6 + \log M_{\text{PSO}})\}$

Portanto, os resultados numéricos obtidos mostraram que o $\text{ACO}_{\mathbb{R}}$ pode ser competitivo em relação ao CvX quando aplicado ao problema WTM em redes MPG-DS/CDMA. Isso pois, a meta-heurística foi capaz de atingir níveis aceitáveis de fluxo total de informação em relação ao ótimo (CvX), ao custo de maiores níveis de potência de transmissão, mas ao mesmo tempo, com tempo de execução muito menor. Ainda neste contexto, a tabela 4.7 mostrou que a diferença em relação ao tempo de execução das abordagens aumenta conforme o número de




Figura 4.13: Numero de operações de ponto flutuante para os algoritmos $ACO_{\mathbb{R}}$ e PSO.

usuários aumenta. Verificar até que ponto (em relação ao carregamento do sistema) esta diferença aumenta, e ao mesmo tempo, até que ponto o $ACO_{\mathbb{R}}$ é capaz de convergir com níveis aceitáveis de $\sum R$ e $\sum P$ é uma questão que encontra-se em aberto, e que pode ser vista como uma proposta para trabalhos futuros. No entanto, nos níveis de carregamento de sistema considerados, ficou claro que a abordagem baseada na meta-heurística $ACO_{\mathbb{R}}$ é competitiva, e se mostrou útil na obtenção de sistemas que façam uso eficiente de energia e espectro, para a próxima geração das redes sem fio.

4.3 Maximização da Eficiência Energética

Nesta seção, as abordagens heurísticas baseadas nos algoritmos $ACO_{\mathbb{R}}$ e PSO serão analisadas em relação à ferramenta analítica para otimização convexa disciplinada CVX [CVX Research, Inc. 2012], todas aplicadas no *loop* interno do método de Dinkelbach [Dinkelbach 1967, Schaible 1976] (DM-ACO, DM-PSO e DM-CVX). Os parâmetros de sistema considerados são apresentados na Tabela 4.9. No entanto, a fim de garantir que ambas as meta-heurísticas estão sendo usadas da melhor maneira possível, primeiramente, uma análise exhaustiva dos parâmetros de entrada será desenvolvida.

Tabela 4.9: Parâmetros do Sistema DS/CDMA Macro-Celular Multi-Taxa e de Canal

Parâmetros	Valores Adotados
<i>Sistema DS/CDMA com Alocação de Potência e Taxa de Informação</i>	
Potência de Ruído	$P_n = 0.1$ [W]
Largura de Banda CDMA	$r_c = 5$ [MHz]
Potência Máxima Por Usuário	$p_{\max} = 3$ [W]
Ineficiência do Amplificador RF	$\iota = 2.7$
Potência de Circuitaria	$P_c = 0.32 \cdot U$ [W]
Ordem de Modulação	$m_i = 2$ (QPSK) $\forall i$
# Usuários por Classe	$\{U^{\text{VOZ}}; U^{\text{VÍDEO}}; U^{\text{DADOS}}\}$
$U = [12, 20, 30]$:	$\{[6; 4; 2], [9; 6; 5], [16; 9; 5]\}$
<i>Tipo de Desvanecimento de Canal</i>	
Perda de Percurso	$\propto d^{-2}$
Sombreamento	Log-normal, $\sigma^2 = 6$ dB
Desvanecimento Multi-Percurso	Rayleigh
Seletividade no tempo	lenta
<i>Características dos Usuários e QoS</i>	
Classes de Serviço	[VOZ; VÍDEO; DADOS]
Taxas de Usuário ($\frac{r_c}{F_i}$)	$r_{i,\min} = [\frac{r_c}{256}; \frac{r_c}{16}; \frac{r_c}{8}]$ [bps]
BER Alvo de Usuário, $\text{BER}_{\text{serv}}^*$	$[5 \times 10^{-3}; 5 \times 10^{-5}; 5 \times 10^{-8}]$
Taxa de informação base (mínima)	$r = 19.5$ [kbps]

4.3.1 Calibragem de Parâmetros para o DM-ACO

A calibragem de parâmetros realizada nesta seção foi baseada no trabalho desenvolvido em [Filho, Souza e Abrão 2012], onde um método iterativo para a determinação ótima dos parâmetros de entrada de uma meta-heurística foi proposto. Nesta abordagem, uma configuração inicial dos parâmetros de entrada obtida de forma não-exaustiva é estabelecida. Então, cada parâmetro é testado através do seu domínio, enquanto os outros parâmetros são mantidos em seus valores iniciais. Nas figuras 4.14 e 4.15, os parâmetros q , ξ e α do DM-ACO foram testados em um sistema com $U = 12$ usuários, e apresentados como uma função do NMSE obtido (eixo y esquerdo), e do número de iterações no *loop* externo (eixo y direito). Na primeira etapa da otimização (Fig. 4.14), a configuração inicial dos parâmetros foi dada por $\{q, \xi, \alpha, M_{\text{ACO}}, L\} = \{0, 1; 1, 2; 1, 2; 12; 4\}$; o parâmetro q está variando no intervalo $q \in [0, 0.1; 0, 5]$, espaçado por 0,05 a cada passo. O parâmetro ξ , por sua vez, está variando no intervalo $\xi \in [0, 1; 1, 3]$, com passos de 0,1. Finalmente, o parâmetro α está variando em $\alpha \in [0, 1; 2, 0]$, espaçado por 0,1 em cada passo.

A partir dos gráficos da Figura 4.14, pode-se concluir imediatamente que a melhor configuração para os parâmetros q , ξ e α é dada por $q = 0,45$, $\xi = 1,3$ e $\alpha = 0,7$. Além disso, é notável que todos os parâmetros tiveram um bom comportamento em relação ao NMSE e número de iterações obtido, isto é, existe apenas uma região promissora de valores para cada parâmetro. A seguir, a se-




Figura 4.14: Otimização dos parâmetros de entrada do DM-ACO para $U = 12$ e $\mathcal{T} = 1000$ execuções. NMSE e número de iterações no *loop* externo como funções dos valores dos parâmetros q , ξ e α . A variação dos parâmetros na primeira etapa da otimização: $q \in [0, 01; 0, 5]$, $\xi \in [0, 1; 1, 3]$, $\alpha \in [0, 1; 2, 0]$.




Figura 4.15: Otimização dos parâmetros de entrada do DM-ACO para $U = 12$ e $\mathcal{T} = 1000$ execuções. NMSE e número de iterações no *loop* externo como funções dos valores dos parâmetros q , ξ e α . A variação dos parâmetros na segunda etapa da otimização: $q \in [0, 4; 0, 5]$, $\xi \in [1, 25; 1, 35]$, $\alpha \in [0, 65; 0, 75]$.

gunda etapa da otimização dos parâmetros de entrada para o DM-ACO é apresentada na Figura 4.15. Neste caso, um novo teste é feito na vizinhança dos melhores valores de parâmetros encontrados na primeira etapa da otimização, com maior precisão nos passos. Assim, os valores iniciais assumidos para cada parâmetro são: $\{q, \xi, \alpha, M_{ACO}, L\} = \{0, 45; 1, 3; 0, 7; 12; 4\}$. Os testes do parâmetro q estão sendo feitos no intervalo $q \in [0, 4; 0, 5]$, em passos espaçados por 0,01. O parâmetro ξ , por sua vez, foi testado no intervalo $\xi \in [1, 5; 1, 35]$, em passos de 0,01, e o parâmetro α no intervalo $\alpha \in [0, 65; 0, 75]$, com passos espaçados também por 0,01. Terminados os dois passos da otimização, pode ser visto que a melhor configuração de parâmetros de entrada para o algoritmo DM-ACO aplicado ao problema de maximização da eficiência energética total do sistema ($\sum EE$) MPG-DS/CDMA, obtido em uma busca exaustiva, com $U = 12$ usuários é: $\{q, \xi, \alpha, M_{ACO}, L\} = \{0, 48; 1, 3; 0, 68; 12; 4\}$.

Adicionalmente, os parâmetros M_{ACO} e L foram obtidos em um simples procedimento, onde o menor valor capaz de garantir a convergência do algoritmo foi selecionado. Desta forma, os valores dos parâmetros M_{ACO} e L foram fixados em $M_{ACO} = U$ e $L = \{4; 12; 14\}$ para os sistemas com $U = \{12; 20; 30\}$ usuários, respectivamente. Além disso, $L = 4$ foi fixado quando o número de usuários é menor que $U = 12$.

É notável também o fato de que o número de iterações T_{DM-ACO} diminui quando o valor dos parâmetros de entrada que determinam a complexidade do algoritmo (os parâmetros q e ξ) aumenta. Isso é devido ao fato de que o $ACO_{\mathbb{R}}$ está sendo aplicado no *loop* interno do método de Dinkelbach; portanto, o número de iterações T_{DM-ACO} mostrado nas Figuras 4.14 e 4.15 representa o número de iterações externas do algoritmo, o que indica que o desempenho do $ACO_{\mathbb{R}}$ aumenta quando o valor destes parâmetros aumenta, uma vez que o método de Dinkelbach utiliza um número menor de iterações. Uma análise mais aprofundada em relação ao número de iterações no *loop* externo devido ao desempenho do algoritmo empregado no *loop* interno do DM é apresentada na seção 4.3.3.

A fim de demonstrar o impacto da escolha dos parâmetros de entrada do DM-ACO considerando outros carregamentos de sistema, as Figuras 4.16, 4.17 e 4.18 mostram o NMSE em função do número de usuários U e dos parâmetros de entrada q ; ξ e α , respectivamente, variando através de seus respectivos domínios. A partir da Figura 4.16, pode ser visto que a melhor configuração para o parâmetro q quando o número de usuários vai de $U = 20$ para $U = 30$ está ao redor de $q = 0, 35$, que por sua vez é um valor menor que no caso com $U = 12$ usuários ($q = 0, 48$). Isso ocorre pois, quando o número de usuários é pequeno, maiores va-

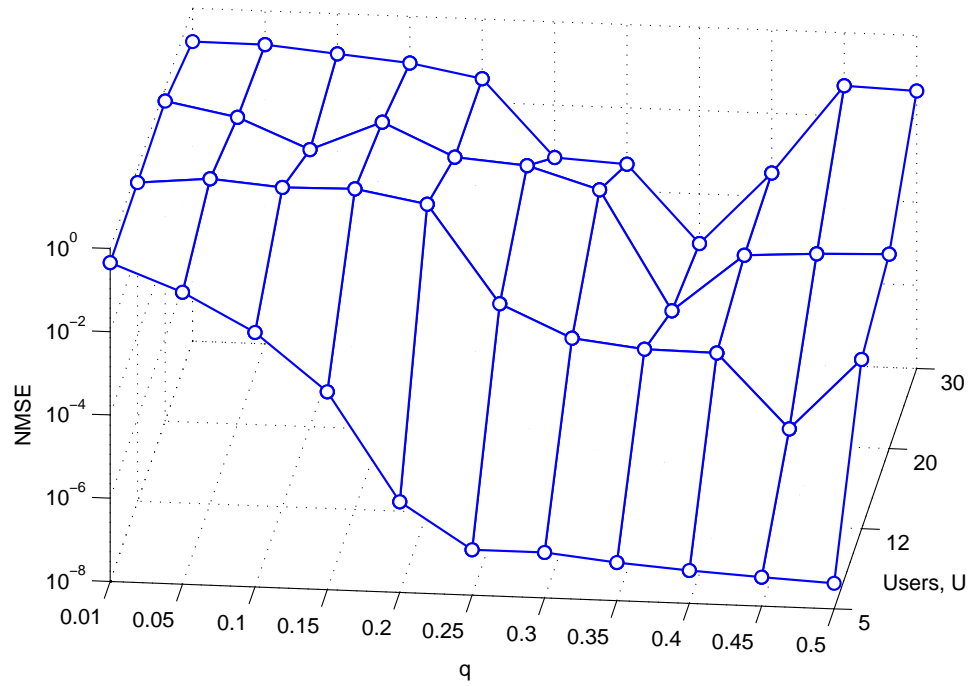


Figura 4.16: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada q em $\mathcal{T} = 1000$ realizações.




Figura 4.17: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada ξ em $\mathcal{T} = 1000$ realizações.




Figura 4.18: NMSE em função do número de usuários (U) e de valores experimentais para o parâmetro de entrada α em $\mathcal{T} = 1000$ realizações.

lores de q são necessários a fim de evitar a convergência prematura do algoritmo, e quando o número de usuários é grande, menores valores de q evitam a estagnação do algoritmo devido à lenta convergência em um problema de grande dimensionalidade. Apesar disso, essas características podem variar de acordo com a função custo analisada, e pode ser que para alguns casos os melhores valores de q sejam diretamente proporcionais à dimensionalidade do problema. Isso torna evidente a importância da calibragem de parâmetros para meta-heurísticas, principalmente, o $\text{ACO}_{\mathbb{R}}$.

A Figura 4.17 mostra que o melhor valor para o parâmetro ξ quando $U \geq 20$ também é menor que o melhor valor encontrado quando $U = 12$. Finalmente, a Figura 4.18 mostra que o parâmetro α apresenta o mesmo comportamento dos parâmetros q e ξ ; este resultado é razoável, uma vez que o parâmetro α representa a volatilidade do algoritmo $\text{ACO}_{\mathbb{R}}$ no *loop* interno do DM. Portanto, quando mais complexo for o problema a ser otimizado, mais volátil o algoritmo deve ser.

4.3.2 Calibragem de Parâmetros para o DM-PSO

A primeira etapa do processo de otimização dos parâmetros de entrada para o DM-PSO em um sistema com $U = 12$ usuários é apresentada na Figura 4.19. Os parâmetros ϕ_1 , ϕ_2 , w e α são apresentados como uma função do NMSE e das iterações no *loop* externo do DM, com valores iniciais dados por $\{\phi_1, \phi_2, \omega, \alpha, M_{\text{PSO}}\} =$

$\{2; 2; 0, 5; 0, 6; 120\}$. Os parâmetros ϕ_1 e ϕ_2 foram testados no intervalo $\phi_1, \phi_2 \in [0; 2]$, em passos de 0,2. O parâmetro ω está variando no intervalo $\omega \in [0; 1]$, com passos de 0,1. Finalmente, o parâmetro α varia no intervalo $\alpha \in [0; 2]$ em passos de 0,1. Na Figura 4.19, pode-se verificar que os parâmetros do DM-PSO também são bem comportados em relação ao NMSE e ao número de iterações no *loop* externo, ou seja, existe apenas uma região de valores factíveis para estes parâmetros. Apesar disso, os parâmetros ϕ_1 , ϕ_2 e α são praticamente estáveis para alguns valores, diferentemente de ω , que apresenta o melhor valor ao redor de $\omega = 0,3$.




Figura 4.19: NMSE e número de iterações no *loop* externo (T_{DM-PSO}) em função dos parâmetros de entrada ϕ_1 , ϕ_2 , ω e α para $U = 12$ usuários e $\mathcal{T} = 1000$ realizações. Os parâmetros de entrada para o DM-PSO variam no intervalo $\phi_1, \phi_2 \in [0; 2]$, $\omega \in [0; 1]$, $\alpha \in [0; 2]$ no primeiro passo de otimização.

Os resultados para a segunda etapa do processo de otimização de parâmetros para o DM-PSO são apresentados na Figura 4.20, onde os valores iniciais são os melhores encontrados na primeira etapa do processo de otimização $\{\phi_1, \phi_2, \omega, \alpha, M_{PSO}\} = \{1; 1; 0, 3; 1, 5; 120\}$. Agora, os parâmetros estão variando em um intervalo mais restrito, como $\phi_1 \in [0; 1, 4]$ em passos de 0,05; o parâmetro $\phi_2 \in [0, 8; 1, 4]$, em passos de 0,05; ω , por sua vez, em $\omega \in [0, 25; 0, 35]$ com passos de 0,01, e $\alpha \in [1; 2]$ com passos de 0,2. Pode ser visto que o número de iterações no *loop* externo é constante para todos os parâmetros. Além disso, $T_{DM-PSO} = 10$ é maior que $T_{DM-ACO} = 7$, o que confirma a superioridade do $ACO_{\mathbb{R}}$ em relação ao PSO ao maximizar a função interna do DM. Vale ressaltar que esta diferença




Figura 4.20: NMSE e número de iterações no *loop* externo ($N_{\text{DM-PSO}}$) em função dos parâmetros de entrada ϕ_1 , ϕ_2 , ω e α para $U = 12$ usuários e $\mathcal{T} = 1000$ realizações. Os parâmetros de entrada para o DM-PSO variam no intervalo: $\phi_1 \in [0, 2; 1, 4]$, $\phi_2 \in [0, 8; 1, 4]$, $\omega \in [0, 25; 0, 35]$, $\alpha \in [1; 2]$. no segundo passo de otimização.

aumenta de forma diretamente proporcional ao carregamento do sistema.




Figura 4.21: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ϕ_1 .

As Figuras 4.21, 4.22, 4.23 e 4.24 apresentam o NMSE para o DM-PSO em




Figura 4.22: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ϕ_2 .




Figura 4.23: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada ω .




Figura 4.24: NMSE para o algoritmo DM-PSO em função do número de usuários (U) e do parâmetro de entrada α .

função do número de usuários (U) e os valores dos parâmetros ϕ_1, ϕ_2, ω e α , respectivamente. Para testes feitos em um amplo intervalo de valores, a perda de desempenho do DM-PSO é evidente quando o carregamento do sistema vai além de $U = 20$ usuários. Por outro lado, é visível que o comportamento do NMSE em função dos parâmetros de entrada do DM-PSO é mais suave que para o DM-ACO, indicando que a calibragem de parâmetros é mais crítica quando se trata do $ACO_{\mathbb{R}}$.

Uma análise mais aprofundada do compromisso desempenho-complexidade é desenvolvida na seção 4.3.4. Finalmente, a melhor configuração de parâmetros para o DM-PSO em um sistema com $U = 12$ usuários é: $\{\phi_1, \phi_2, \omega, \alpha, M_{\text{PSO}}\} = \{0, 55; 1, 3; 0, 3; 1, 5; 120\}$. Além disso, para o DM-PSO, foram encontrados valores fixos para o tamanho da população $M_{\text{PSO}} = 10 \cdot U$, que por sua vez, é o menor valor no qual foi possível garantir a convergência do algoritmo. A Tabela 4.10 apresenta os parâmetros de entrada calibrados de forma exaustiva para os algoritmos DM-ACO e DM-PSO aplicados ao problema de maximização da eficiência energética total ($\sum EE$) do sistema MPG-DS/CDMA.

4.3.3 Maximização da Eficiência Energética

Nesta seção, o problema de maximização da eficiência energética total ($\sum EE$) do sistema MPG-DS/CDMA será investigado sob a perspectiva das meta-heurísticas

Tabela 4.10: Parâmetros de entrada otimizados para os algoritmos DM-ACO_R e DM-PSO

Parâmetros	Valores Adotados
Parâmetros do DM-ACO _R	
Tamanho da População	$M_{ACO} = U$;
Tamanho do Arquivo de Soluções	$L \in [4; 12; 14]$;
Fator de Diversidade	$q = [0, 48; 0, 37; 0, 33]$;
Taxa de Evaporação de Feromônio	$\xi = [1, 3; 0, 89; 1, 04]$;
Coefficiente de Volatilidade	$\alpha = [0, 68; 0, 59; 0, 55]$;
Max. # iterações	$T_{ACO} = 1000$;
Parâmetros do DM-PSO	
Tamanho da População	$M_{PSO} = 10 \cdot U$;
Peso da Inércia	$\omega \in [0, 3; 0, 32; 0, 32]$;
Coefficiente de Aceleração Local	$\phi_1 \in [0, 55; 0, 5; 0, 5]$;
Coefficiente de Aceleração Global	$\phi_2 \in [1, 3; 1; 1]$;
Coefficiente de Volatilidade	$\alpha = [1, 5; 0, 8; 0, 8]$;
Max. # iterações	$T_{PSO} = 1000$;

ACO_R [Socha e Dorigo 2008, Marques et al. 2012], PSO [Kennedy e Eberhart 1995, Abrão et al. 2011], da ferramenta analítica para otimização convexa disciplinada CVX [CVX Research, Inc. 2012], e do método de Dinkelbach [Dinkelbach 1967, Schaible 1976].

Visando analisar o desempenho dos três algoritmos propostos, o mesmo vetor de potências iniciais foi considerado para todos os algoritmos, em todos os casos estudados. Além disso, os ganhos de canal, obtidos a partir de uma distribuição Rayleigh também foram mantidos estáticos e idênticos para os três algoritmos abordados. Resultados ilustrativos para a maximização da $\sum EE$ são apresentados nas Figuras 4.25 e 4.26. As Figuras 4.25.a e 4.25.b apresentam resultados para a eficiência energética total do sistema ($\sum EE$) como uma função da potência de transmissão alocada para o primeiro e o último usuário, p_1 e p_{30} , respectivamente, enquanto os outros usuários mantêm seus níveis de potência ótimos obtidos no fim do processo de otimização, ex., $T_{DM-ACO, DM-CVX} = 6, T_{DM-PSO} = 40$. Para o DM-ACO e o DM-CVX, está claro que depois de 3 ou 4 iterações, o primeiro e o último usuário já são capazes de atingir patamares muito próximos do ótimo da função custo. E com isso, o sistema atinge então o ponto de operação com máxima eficiência espectral. Por outro lado, o DM-PSO evolui lentamente, e só é capaz de convergir completamente depois de um grande número de iterações no *loop* externo ($T_{DM-PSO} = 40$).

A Figura 4.26 mostra as taxas de informação atingidas em relação às mínimas necessárias para garantir QoS aos usuários, depois de T_{DM} iterações para todos os algoritmos considerados. Portanto, todos os $U = 30$ usuários operam na configuração de máxima $\sum EE$ com seus requisitos de QoS satisfeitos. Desta

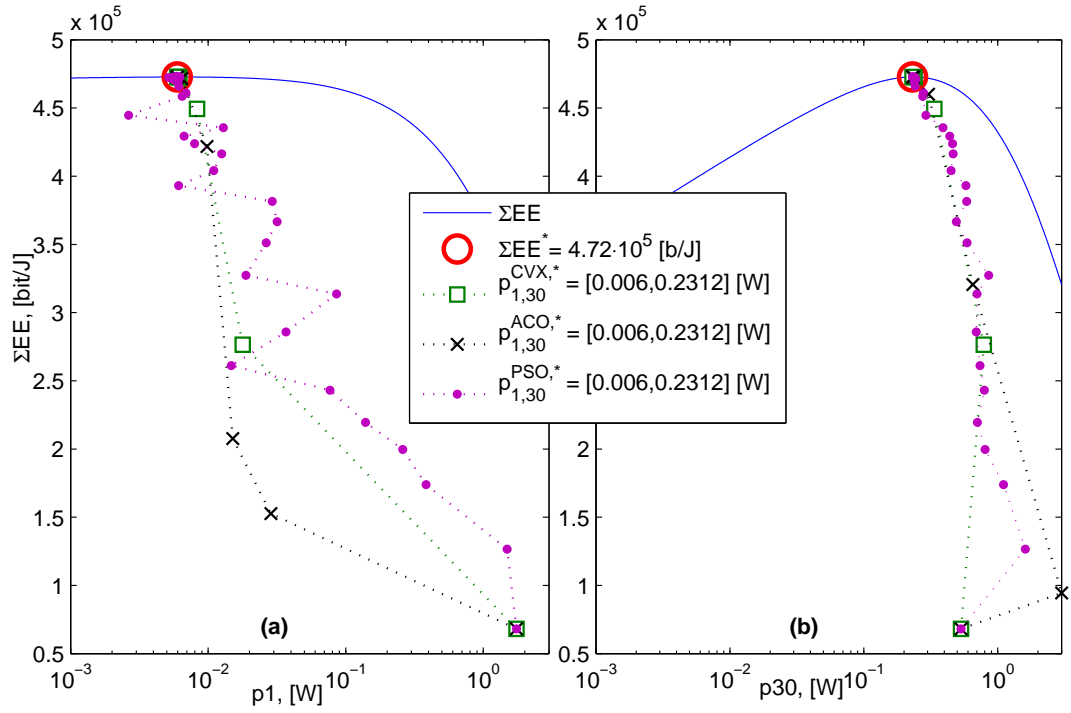


Figura 4.25: Comportamento da ΣEE para o vetor de potências ótimas \mathbf{p}^* , exceto para as potências a) p_1 e b) p_{30} . O número de iterações nos métodos DM: $T_{DM-CVX} = 6$; $T_{DM-ACO} = 6$ obtendo $\epsilon = 10^{-5}$, e $T_{DM-PSO} = 40$ obtendo $\epsilon = 10^{-3}$.

forma, conclui-se que o problema é factível em relação às restrições (C.1)-(C.3) da Equação (2.30). Além disso, os três algoritmos foram capazes de resolver o problema sem violar as restrições apresentadas.

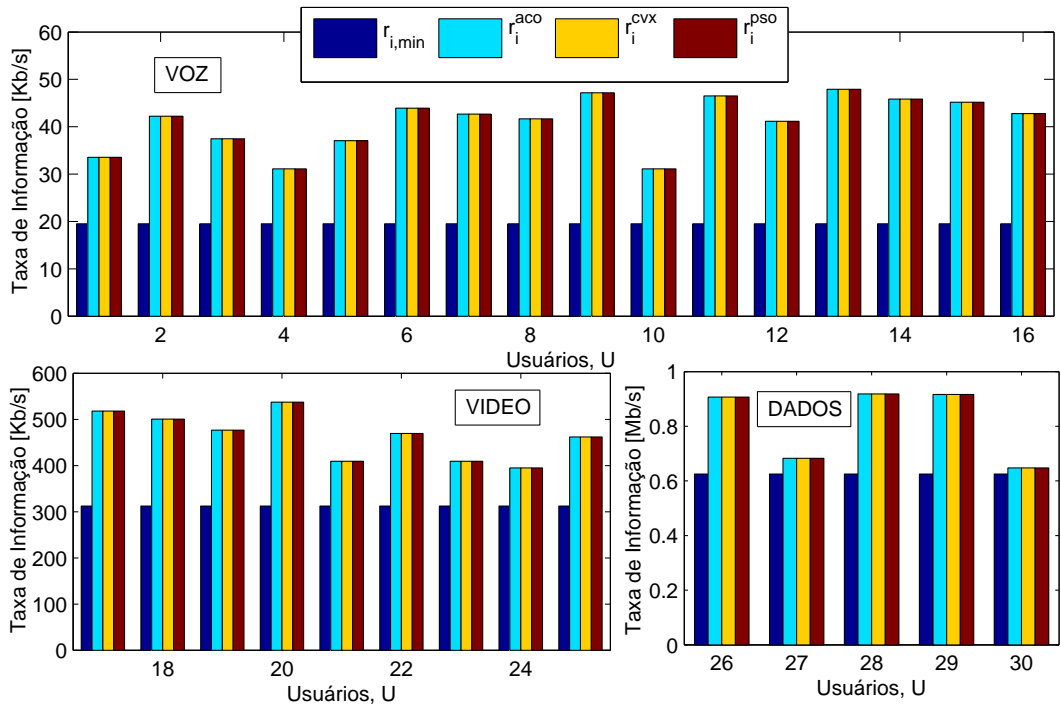


Figura 4.26: Taxas de informação mínimas (QoS) e ótimas ($\max \Sigma EE$) obtidas depois de $T_{DM-CVX} = T_{DM-ACO} = 6$ e $T_{DM-PSO} = 40$ iterações.

A Tabela 4.11 apresenta os resultados obtidos em relação à $\sum EE$, $\sum Taxa$ e $\sum Potência$ para diferentes carregamentos de sistema através dos algoritmos DM-ACO, DM-PSO e DM-CVX. Note que a $\sum EE$ obtida para $U = 20$ usuários é maior que obtida para $U = 12$ usuários. Essa diferença acontece devido à maior "diversidade" de taxas (serviços) no processo de otimização (maior número de usuários de cada classe de serviço no sistema), uma vez que os usuários com maiores taxas de informação (VÍDEO, DADOS) normalmente alcançam maiores valores de eficiência energética (Fig. 4.31).

Tabela 4.11: Resultados obtidos para as métricas de desempenho consideradas nas abordagens analítica (DM-CVX) e meta-heurística (DM-ACO, DM-PSO).

Métrica \sum	$U = 2$	$U = 12$	$U = 20$	$U = 30$
EE [bpJ]	$6,517 \cdot 10^5$	$5,252 \cdot 10^5$	$5,439 \cdot 10^5$	$4,727 \cdot 10^5$
Taxa [bps]	$8,760 \cdot 10^5$	$3,735 \cdot 10^6$	$6,831 \cdot 10^6$	$8,183 \cdot 10^6$
Potência [W]	1,344	7,110	12,559	17,309

A figura 4.27 apresenta a evolução do NMSE para o DM-ACO e o DM-PSO em relação à solução obtida pelo DM-CVX considerando $\mathcal{T} = 1000$ realizações para ambos os algoritmos. Como referência, o limite $NMSE^{th} = 10^{-2}$ foi considerado a fim de obter no máximo 1% de erro no vetor de potência aproximado em relação ao ótimo (que garante a $\sum EE^*$) obtida pelo DM-CVX. Está claro que depois de cinco iterações do *loop* externo, o DM-ACO é capaz de obter $NMSE \leq 10^{-2}$ para todos os carregamentos de sistema considerados, e em mais uma iteração, é capaz de obter $NMSE \approx 10^{-5}$. Além disso, o NMSE continua melhorando além de 10^{-5} , mostrando que o $ACO_{\mathbb{R}}$ é suficientemente robusto para realizar a otimização da função interna do método de Dinkelbach. Por outro lado, está claro que o DM-PSO precisa de quase seis vezes mais iterações no *loop* externo do que o DM-ACO para alcançar um $NMSE \leq NMSE^{th}$ quando $U > 12$.

As Figuras 4.28 e 4.29 mostram a evolução do $\sum EE$, e do correspondente $\sum Potência$ para os três algoritmos. Para o DM-ACO e DM-CVX, pode-se notar que a evolução é praticamente idêntica, devido aos valores de potência iniciais que foram mantidos iguais à todos os algoritmos, e também aos ganhos de canal estáticos. Ademais, isso não seria possível, se não fosse a alta capacidade do $ACO_{\mathbb{R}}$ em resolver as funções internas do DM. Uma vez que o DM-ACO atinge o mesmo número de iterações que o DM-CVX, pode-se concluir que o $ACO_{\mathbb{R}}$ é uma meta-heurística robusta quando aplicada em conjunto com o método de Dinkelbach. De fato, o $ACO_{\mathbb{R}}$ é capaz de convergir completamente depois de cinco iterações no *loop* externo. Não obstante, o algoritmo DM-PSO é consideravelmente menos complexo em relação ao DM-ACO. Portanto, quando a dimensão do problema cresce ($U > 12$), o DM-PSO precisa de pelo menos seis vezes o número de iterações




Figura 4.27: Evolução do NMSE para os algoritmos DM-ACO e DM-PSO com $U = [5; 12; 20; 30]$ usuários.

no *loop* externo que o DM-CVX para atingir a convergência total. No entanto, apesar do maior número de iterações utilizadas pelo algoritmo, não é possível obter nenhuma conclusão no que tange à sua complexidade computacional, dado que este ainda ultrapassa o limite definido em NMSE (menos de 1% de erro no vetor de potência), ou seja, não é possível obter nenhuma conclusão sobre a complexidade computacional de um algoritmo analisando apenas o número de iterações utilizado.

Ficou claro que o PSO não é capaz de convergir completamente quando a dimensão do problema cresce, e como resultado, o $\sum EE$ e o \sum Potência evoluem lentamente como pode ser visto nas Figs. 4.28 e 4.29 para o caso em que $U = 30$ usuários. A fim de quantificar a perda de desempenho do DM-PSO, a evolução da função custo η_E através do número de iterações no *loop* interno do DM é apresentada na Figura 4.30. Apesar do grande número de iterações necessárias para atingir a convergência ($\approx T_{ACO_{\mathbb{R}}} = 150$), o $ACO_{\mathbb{R}}$ foi capaz de resolver o problema em um tempo de execução menor que o CVX, e ao mesmo tempo, obter um desempenho similar. Note que para a ferramenta CVX, os valores instantâneos das variáveis internas não são acessíveis durante o processo de otimização, e portanto, uma convergência linear foi assumida.

A partir da Figura 4.30, os problemas de convergência do algoritmo PSO tornam-se evidentes: mesmo adotando um tamanho de população excessivamente




Figura 4.28: Evolução da ΣEE para os algoritmos DM-ACO, DM-PSO and DM-CVX em função das iterações no *loop* externo, considerando $U \in \{5; 12; 30\}$ usuários.




Figura 4.29: Evolução da ΣP para os algoritmos DM-ACO, DM-PSO and DM-CVX em função das iterações no *loop* externo, considerando $U \in \{5; 12; 30\}$ usuários.




Figura 4.30: Evolução no *loop* interno do método DM (Algoritmo 1) para os algoritmos $\text{ACO}_{\mathbb{R}}$, CVX e PSO durante a primeira iteração; $U = 30$ usuários.

grande ($M_{\text{PSO}} = 10 \cdot U$), e um grande número de iterações ($N = 1000$), o PSO não foi capaz de maximizar a função interna do DM. Uma vez que o PSO não encontra o máximo da função interna do DM, o DM-PSO evolui mais lentamente, fazendo com que muito mais iterações sejam necessárias no *loop* externo para atingir um desempenho similar ao DM-ACO. De fato, o $\text{ACO}_{\mathbb{R}}$ alcança o máximo da função interna do DM depois de ≈ 150 iterações no *loop* interno. A partir dos resultados anteriores, pode-se concluir que as evoluções do DM-ACO e do DM-CVX em relação às métricas consideradas são idênticas em todos os carregamentos de sistema considerados.

As Figs. 4.31, 4.32 e 4.33 mostram a evolução das eficiências energéticas, das potências de transmissão e das taxas de informação individuais em um sistema com $U = 12$ para os três algoritmos considerados, respectivamente. Nenhuma das evoluções de nenhuma das métricas é monotônica, para nenhum dos algoritmos analisados, devido ao fato de que o objetivo do algoritmo é maximizar a eficiência energética total do sistema, e não as individuais. E vale ressaltar que, o ponto de máxima eficiência energética individual não necessariamente corresponde ao ponto de máxima eficiência energética total do sistema, em relação ao vetor de potências. Adicionalmente, a similaridade vista entre as evoluções das métricas para os algoritmos DM-ACO e o DM-CVX é devido à convergência praticamente




Figura 4.31: Evolução das EE's individuais para os algoritmos a) DM-ACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários.




Figura 4.32: Evolução das potências individuais para os algoritmos a) DM-ACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários.




Figura 4.33: Evolução das taxas de informação individuais para os algoritmos a) DM-ACO; b) DM-CVX e c) DM-PSO. $U = 12$ usuários.

ótima obtida pelo $ACO_{\mathbb{R}}$ no *loop* interno do método de Dinkelbach (Fig. 4.30). Note que ambos os algoritmos são capazes de encontrar o ponto de equilíbrio em poucas iterações (quatro ou cinco).

4.3.4 Análise de Complexidade Computacional

Uma vez que a complexidade computacional do PSO é muito pequena em relação ao $ACO_{\mathbb{R}}$, e também visando propor um método eficiente em relação ao compromisso robustez *versus* complexidade computacional, uma análise de desempenho considerando a robustez e o tempo de execução dos algoritmos DM-ACO, DM-PSO e DM-CVX é realizada a seguir.

Os resultados numéricos deste capítulo confirmaram a superioridade do $ACO_{\mathbb{R}}$ em relação ao PSO no que tange à robustez, o que já era esperado dado que o $ACO_{\mathbb{R}}$ é intrinsecamente mais complexo. A Tabela 4.12 apresenta as porcentagens de $\sum EE$, $\sum Taxa$, $\sum Potência$ e Robustez (Eq. (3.3)) obtidos através dos algoritmos meta-heurísticos considerados em relação ao DM-CVX para diferentes valores de tolerância ϵ_{min} . Pode ser visto que para todos os carregamentos de sistema considerados, ambas as meta-heurísticas alcançaram 100% de robustez, que por sua vez, garantem a estabilidade do algoritmo e provam sua capacidade em resolver o problema do $\sum EE$. Além disso, o desempenho do DM-ACO e do DM-PSO não se deteriora quando altos valores de tolerância são atribuídos ($\epsilon_{min} = 10^{-2}$) para o DM. Portanto, pode-se reduzir o tempo de execução do algoritmo (diminuindo

a precisão da condição de parada) sem perda de desempenho considerável.

Tabela 4.12: Porcentagem média de sucesso em $\mathcal{T} = 1000$ realizações para os algoritmos DM-ACO e DM-PSO em relação ao DM-CVX após T_{DM} iterações, obtidas a partir da Fig. 4.28 para diferentes valores de ϵ_{min} .

Precisão do DM	Métrica	$U = 5$	$U = 12$	$U = 20$	$U = 30$
ϵ_{min} no intervalo [10^{-5} ; 10^{-2}]	$\sum EE$	100%	100%	100%	100%
	$\sum Taxa$	100%	100%	100%	100%
	$\sum Potência$	100%	100%	100%	100%
	Robustez	100%	100%	100%	100%

A Figura 4.34 apresenta o tempo de execução em função do número de usuários U do sistema para os algoritmos DM-ACO, DM-PSO e DM-CVX, através de diferentes valores de ϵ_{min} . Pode-se verificar que o tempo de execução do DM-PSO é maior que o do DM-ACO quando $U \geq 12$ usuários. Isso é devido ao baixo desempenho do PSO ao maximizar a função interna do método de Dinkelbach (4.30), uma vez que o número máximo de iterações ($T_{PSO} = 1000$) sempre é utilizado. Além disso, o maior número de iterações no *loop* externo utilizado pelo DM-PSO quando $U > 12$ resulta em um tempo de execução que cresce proibitivamente. Portanto, está claro que o grande tamanho de população necessário ($M_{PSO} = 10 \cdot U$) combinado com o grande número de iterações nos *loops* internos e externos, fez com que o DM-PSO se tornasse uma abordagem cara em termos de complexidade computacional. No caso, o DM-ACO obteve o menor tempo de execução para todos os diferentes ϵ_{min} , devido ao seu pequeno tamanho de população e conjunto com as poucas iterações utilizadas nos *loops* internos e externos (o mesmo que o DM-CVX para o *loop* externo). Além disso, a Tabela 4.12 mostra que o ato de aliviar a precisão da condição de parada do algoritmo não afeta a qualidade e a estabilidade dos resultados. Portanto, pode-se utilizar o DM-ACO com $\epsilon_{min} = 10^{-2}$ para obter uma implementação expedita e robusta para o problema de maximização da $\sum EE$. Além disso, a fim de reduzir ainda mais o tempo de execução do algoritmo, pode-se diminuir os requisitos de convergência para a meta-heurística, por exemplo, para $\sum EE \geq 0,97 \cdot \sum EE^*$.

Finalmente, a fim de fornecer uma análise concisa com relação à complexidade dos algoritmos, o número de operações necessário para ambas as meta-heurísticas é apresentado na Tabela 4.13 e na Figura 4.35. A análise de complexidade com relação ao número de operações foi desenvolvida através do conceito de operações de ponto flutuante por segundo (*Floating Point Operation per Second - flops*) [Higham 2002], que considera apenas aquelas instruções com tempo de execução relevante. Neste trabalho, as operações de multiplicação, adição, subtração e divisão foram consideradas de custo computacional equivalente. Além




Figura 4.34: Tempo de execução dos algoritmos DM-ACO, DM-CVX e DM-PSO ao resolver o problema de maximização da eficiência energética total do sistema DS/CDMA no *downlink*.

disso, o custo computacional das operações de ordenação, transposição, comparação, troca, geração de números aleatórios e seleção são considerados proporcionais ao tamanho do problema, por exemplo, o tamanho do vetor ou o número de elementos de uma matriz.

Tabela 4.13: Número de operações para os algoritmos DM-ACO e DM-PSO.

Número de Operações	
T_{DM-ACO}	$\sum_{t=1} T_{ACO,t} \cdot \{M_{ACO}(8 + 8U + 5LU + 3L) + 2U[L(U + 6) + 5] + L(9 + \log L)\}$
T_{DM-PSO}	$\sum_{t=1} T_{PSO,t} \cdot \{U[M_{PSO}(2U + 34) + 12] + M_{PSO}(10 + \log M_{PSO})\}$

A complexidade computacional dos algoritmos DM-ACO e DM-PSO em função dos parâmetros de entrada e do número de iterações no *loop* externo (interno) são apresentadas na Tabela 4.13. A importância da otimização dos parâmetros de entrada para meta-heurísticas fica clara aqui, uma vez que ela é chave para o compromisso robustez *versus* complexidade computacional. Além disso, o ganho obtido por aplicar o método de Dinkelbach no *loop* externo pode ser reduzido se o algoritmo aplicado no *loop* interno não for capaz de maximizar a função paramétrica do DM (Equação (2.35)), dado que um número maior de iterações no *loop* externo vai ser realizado. O número de operações necessário para os algoritmos DM-ACO e DM-PSO obterem convergência aceitável, apresentado nas Figuras 4.34 e 4.35, confirmaram que o número de operações realizadas pelo DM-PSO aumenta proibitivamente quando a dimensionalidade do problema vai além

de $U \geq 5$ usuários, isto é, quando o DM-PSO não é capaz de resolver o problema de maximização da $\sum EE$ com o mesmo número de iterações no *loop* externo que o DM-CVX. Além disso, um outro fator chave para a maior complexidade computacional obtida pelo DM-PSO é o número de iterações no *loop* interno, uma vez que ele executou $T_{\text{DM-PSO}} = 1000$ iterações quando $U \geq 12$, enquanto o DM-ACO executou, em média, $T_{\text{DM-ACO}} \approx 150$ iterações em todos os casos.




Figura 4.35: Operações de Ponto Flutuante para os algoritmos DM-ACO e DM-CVX.

A aplicação do algoritmo $\text{ACO}_{\mathbb{R}}$ no problema de maximização da eficiência energética total de um sistema MPG-DS/CDMA no *downlink* foi realizada com sucesso. Os resultados numéricos obtidos comprovaram a superioridade do $\text{ACO}_{\mathbb{R}}$ em relação ao PSO, em termos de complexidade computacional e robustez. Neste contexto, a superioridade em termos de robustez era esperada, e no mínimo obrigatória dado que o $\text{ACO}_{\mathbb{R}}$ é naturalmente mais complexo que o PSO, devido às técnicas de escape de ótimos locais que implementa. Apesar disso, a aplicação do método de Dinkelbach [Dinkelbach 1967] no *loop* externo do algoritmo, em conjunto com a calibragem exaustiva dos parâmetros de entrada, possibilitou que ambas as meta-heurísticas fossem capazes de garantir solução ótima (99,999% $\sum EE^*$). Adicionalmente, o ganho advindo do DM torna-se custoso caso o algoritmo aplicado no *loop* interno não seja capaz de maximizar a função interna da Eq. (2.34). Isso fez com que o $\text{ACO}_{\mathbb{R}}$ superasse o PSO em relação à complexidade computacional. Finalmente, conforme visto na Fig. 4.25, o algoritmo proposto é capaz de maximizar a Eficiência Energética total do sistema, e

portanto, mostrou-se útil na obtenção de sistemas que atendam os requisitos das futuras redes de comunicação, também conhecidas como *Green Communication Networks*.

4.4 MPA, WTM e EED

Nesta seção, uma análise foi realizada abordando os três problemas de alocação de recursos em redes de múltiplo acesso apresentados neste trabalho, no que tange sua aplicação no projeto de sistemas. A Fig. 4.36 apresenta a $\sum P$, $\sum R$ e $\sum EE$ em função do número de usuários no sistema. Todos os resultados apresentados nesta figura foram gerados a partir da mesma configuração de sistema. Nesta figura, fica claro que a alocação de potência mínima não resulta em economia de bateria, mas em um aumento na capacidade da ERB em termos de usuários, por reduzir consideravelmente o nível de interferência de múltiplo acesso. O problema WTM, utilizando de três à aproximadamente oito vezes mais $\sum P$, utiliza energia de forma mais eficiente (apesar de marginalmente) que o MPA, reforçando esta afirmação. Considerando que usuários da classe DADOS objetivam fazer transferências de arquivos (páginas WEB, músicas, imagens, etc.), atribuir maiores taxas de informação à eles abrevia o tempo de duração de suas conexões, e ao mesmo tempo melhora a qualidade do serviço. A redução do tempo de conexão desses usuários implica na redução do tempo em que eles vão contribuir (consideravelmente) para o aumento da MAI. Ainda neste contexto, os usuários das classes VOZ e VÍDEO fazem transferências de dados por meio de conexões cuja duração depende apenas da necessidade do usuário, ou seja, atribuir maiores taxas de informação à eles não abrevia a duração de suas conexões, apenas melhora a qualidade dos serviços prestados. Vale ressaltar que os usuários de VOZ e VÍDEO são muito menos sensíveis à MAI, devidos aos maiores valores de ganho de processamento. A formulação os pesos de cada serviço adotada para o problema WTM, Eq. (2.29) (Sec. 4.2) foi criada a partir deste pensamento.

Quanto ao EED, existem dois fatores que motivam a maximização da eficiência energética de uma rede: Primeiramente, a redução do impacto ambiental devido às emissões de carbono para geração de energia; Em segundo lugar, do ponto de vista das empresas de telecomunicações, é o aumento do lucro a partir da redução dos gastos com energia elétrica. Com o aumento exponencial do número de usuários nas redes de comunicação móveis e a crescente demanda por serviços de multimídia, o aumento no tráfego de dados será um fator dominante e, a menos que estratégias de economia de energia sejam utilizadas, ocorrerá um




Figura 4.36: Análise dos problemas MPA, WTM e EED a partir de $\sum P$, $\sum R$ e $\sum EE$ em função do número de usuários.

grande aumento nas limitações de uso desses dados.

Finalmente, no contexto das empresas de telecomunicações, o aumento do lucro pode ser vislumbrado a partir da maximização da eficiência no uso de energia e espectro. A partir da figura 4.36, pode ser visto que os sistemas operando no ponto de máxima eficiência energética alcançam um nível de taxa de informação total muito menor que o limite (WTM), evidenciando a existência de um compromisso entre as eficiências energética e espectral. Portanto, pode ser encontrado um ponto de operação em que ambas as eficiências (energética e espectral) sejam maximizadas, a fim de reduzir o gasto com energia para a transmissão, mas ao mesmo tempo, utilizar o espectro de forma eficiente. No entanto, este aspecto não foi abordado neste trabalho, e pode ser visto como uma sugestão para trabalhos futuros.

5 Conclusões

A alocação de recursos em redes sem fio de múltiplo acesso torna-se cada vez mais necessária devido às demandas criadas pelo crescente número de usuários de redes sem fio. Com isso, muitos pesquisadores têm trabalhado neste contexto, buscando algoritmos simples e robustos para a alocação de recursos em sistemas sem fio. Sendo assim, o espectro de frequências disponível para as concessionárias têm que suportar uma densidade de usuários cada vez maior. Isso fomentou a evolução das tecnologias de múltiplo acesso (CDMA, OFDMA, MC-CDMA), e com elas, novas técnicas para alocação de recursos foram criadas.

Neste trabalho, uma abordagem meta-heurística foi utilizada a fim de propor soluções de qualidade com baixo custo computacional. Sabe-se que métodos de aproximação vêm sendo utilizados há muito tempo na literatura como uma alternativa aos métodos determinísticos. Além disso, os resultados reportados na literatura mostram constantemente um grande crescimento da qualidade e da robustez destes algoritmos. Com isso, tais métodos são aplicáveis à problemas reais, uma vez que a aproximação alcançada seja suficientemente precisa para que o erro em relação à solução obtida analiticamente seja desprezível. Ainda que este erro não seja desprezível, a aplicação de métodos de aproximação pode ser considerada caso o custo de sua aplicação justifique a perda relativa ao erro. A seção 4.2 deste trabalho pode ser vista como um exemplo para este caso.

Conforme os resultados numéricos obtidos, o $ACO_{\mathbb{R}}$ foi suficientemente robusto para resolver os três problemas de alocação de recursos em redes MPG-DS/CDMA abordados neste trabalho. No problema de alocação de potência mínima, o desempenho do $ACO_{\mathbb{R}}$ superou a do PSO em relação à robustez (Tabela 4.4) em 35% quando comparada à sistemas com $U = 20$ usuários, obtendo maior qualidade de aproximação em todos os carregamentos de sistemas considerados, com menor tempo de execução para $U \geq 10$ usuários. Já no problema WTM, os resultados numéricos obtidos mostraram que o $ACO_{\mathbb{R}}$ pode ser competitivo em relação ao CvX pois, a meta-heurística foi capaz de atingir níveis aceitáveis de fluxo total de informação em relação ao ótimo (CvX), ao custo de maiores níveis

de potência de transmissão, mas com tempo de execução muito menor. Adicionalmente, foi visto que a diferença de desempenho das abordagens em relação ao tempo de execução aumenta conforme a dimensionalidade do problema aumenta. Isso deixa claro o fato de o $\text{ACO}_{\mathbb{R}}$ ser menos complexo em relação ao (CvX). Neste problema o $\text{ACO}_{\mathbb{R}}$ também supero o PSO em termos de robustez e complexidade computacional, dado que o PSO obteve aproximações de menor qualidade (ainda que aceitável) em todas as configurações, e foi nitidamente mais complexo que o $\text{ACO}_{\mathbb{R}}$ quando $U > 20$ usuários.

Os resultados obtidos na resolução do problema EED também comprovaram a superioridade do $\text{ACO}_{\mathbb{R}}$ em relação ao PSO em termos de complexidade computacional e robustez, e a calibragem exaustiva dos parâmetros de entrada das meta-heurísticas confirmou as interpretações apresentadas nos problemas anteriores. Neste contexto, a superioridade em termos de robustez era esperada, e no mínimo obrigatória dado que o $\text{ACO}_{\mathbb{R}}$ é naturalmente mais complexo que o PSO. Apesar disso, a aplicação do método de Dinkelbach [Dinkelbach 1967] no *loop* externo do algoritmo, em conjunto com a calibragem exaustiva dos parâmetros de entrada, possibilitou que ambas as meta-heurísticas fossem capazes de garantir solução ótima (99.999% $\sum \text{EE}^*$). Ademais, o ganho advindo do DM torna-se custoso caso o algoritmo aplicado no *loop* interno não seja capaz de maximizar a função interna da Eq. (2.34). Isso fez com que o $\text{ACO}_{\mathbb{R}}$ superasse o PSO em relação à complexidade computacional.

Portanto, as meta-heurísticas utilizadas neste trabalho foram capazes de encontrar soluções com qualidade de aproximação aceitável nos problemas analisados, com grande redução dos custos computacionais, mostrando que elas podem ser utilizadas em problemas reais onde a limitação de energia e capacidade de processamento sejam problemas significativos para o desenvolvimento de um projeto. Adicionalmente, fica nítido que cada problema abordado pode ser utilizado com diferentes objetivos, dependendo das necessidades da rede a ser projetada.

Referências

- ABRÃO, T.; SAMPAIO, L. D. H.; PROENÇA, M. L.; ANGÉLICO, B. A.; JESZENSKY, P. J. E. Multiple access network optimization aspects via swarm search algorithms. In: *Search Algorithms and Applications*. Rijeka, Croatia: InTech Open, ISBN: 980-953-307-672-5, 2011. v. 1, cap. 13, p. 261–298.
- AHMADI, H.; CHEW, Y. H. Subcarrier-and-bit allocation in multiclass multiuser single-cell ofdma systems using an ant colony optimization based evolutionary algorithm. In: *WCNC*. IEEE, 2010. p. 1–5. ISBN 978-1-4244-6398-5. Disponível em: <<http://dblp.uni-trier.de/db/conf/wenc/wenc2010.html#AhmadiC10>>.
- AHMADI, H.; CHEW, Y. H.; CHAI, C. C. Multicell multiuser ofdma dynamic resource allocation using ant colony optimization. In: *VTC Spring*. IEEE, 2011. p. 1–5. ISBN 978-1-4244-8331-0. Disponível em: <<http://dblp.uni-trier.de/db/conf/vtc/vtc2011s.html#AhmadiCC11>>.
- AL-HEZMI, A.; FRIEDRICH, O.; ARBANOWSKI, S.; MAGEDANZ, T. Requirements for an ims-based quadruple play service architecture. *IEEE Network*, v. 21, n. 2, p. 28–33, April 2007.
- AVRIEL, M.; DIEWERT, W. E.; SCHAIBLE, S.; ZANG, I. *Generalized Concavity*. Philadelphia, PA: Society for Industrial and Applied Mathematics (SIAM), 2010. (Classics in Applied Mathematics Series). ISBN 9780898718966.
- CHIANG, M.; HANDE, P.; LAN, T.; TAN, C.-W. Power control in wireless cellular networks. *Foundations and Trends in Networking*, v. 2, n. 4, p. 381–533, 2007. Disponível em: <<http://dblp.uni-trier.de/db/journals/ftnet/ftnet2.html#ChiangHLT07>>.
- CROUZEIX, J.-P.; FERLAND, J. A. Algorithms for generalized fractional programming. *Math. Program.*, v. 52, p. 191–207, 1991.
- CVX Research, Inc. *CVX: Matlab Software for Disciplined Convex Programming, version 2.0*. Aug. 2012.
- DINKELBACH, W. On nonlinear fractional programming. *Management Science*, INFORMS, v. 13, n. 7, p. pp. 492–498, 1967. ISSN 00251909.
- DORIGO, M.; CARO, G. D. Ant colony optimization: a new meta-heuristic. In: *Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on Evolutionary Computation*. Washington, DC: IEEE Press, 1999. v. 2, p. 1470–1477.
- ELKAMCHOUCI, H.; ELRAGAL, H.; MAKAR, M. Power control in cdma system using particle swarm optimization. In: *National Radio Science Conference, 2007*. Cairo, Egito: IEEE Press, 2007. p. 1–8.

- ELMUSRATI, M.; EL-SALLABI, H.; KOIVO, H. Applications of multi-objective optimization techniques in radio resource scheduling of cellular communication systems. *Wireless Communications, IEEE Transactions on*, v. 7, n. 1, p. 343–353, Jan 2008. ISSN 1536-1276.
- ELNASHAR, A.; EL-SAIDNY, M.; SHERIF, M. *Design, Deployment and Performance of 4G LTE Networks*. first. United Kingdom: Wiley, 2014.
- FAZEL, K.; KAISER, S. *Multi-Carrier and Spread Spectrum Systems*. New York, NY, USA: John Wiley & Sons, Inc., 2003. ISBN 0470848995.
- FILHO, J. C. M.; SOUZA, R. N. de; ABRÃO, T. Ant colony input parameters optimization for multiuser detection in ds/cdma systems. *Expert Systems with Applications*, v. 39, n. 17, p. 12876 – 12884, 2012. ISSN 0957-4174.
- FOSCHINI, G.; MILJANIC, Z. A simple distributed autonomous power control algorithm and its convergence. *Vehicular Technology, IEEE Transactions on*, v. 42, n. 4, p. 641–646, Nov 1993. ISSN 0018-9545.
- GRANT, M. C.; BOYD, S. Graph implementations for nonsmooth convex programs. In: BLONDEL, V.; BOYD, S.; KIMURA, H. (Ed.). *Recent Advances in Learning and Control*. London, UK: Springer London, 2008, (Lecture Notes in Control and Information Sciences, v. 371). p. 95–110. ISBN 978-1-84800-154-1.
- GROSS, T. J.; ABRÃO, T.; JESZENSKY, P. J. E. Algoritmo de controle de potência distribuído fundamentado no modelo populacional de verhulst. *Revista da Sociedade Brasileira de Telecomunicações*, v. 20, n. 2, p. 59–74, 2006.
- GROSS, T. J.; ABRAO, T.; JESZENSKY, P. J. E. Distributed power control algorithm for multiple access systems based on verhulst model. *AEU - International Journal of Electronics and Communications*, v. 65, n. 4, p. 361–372, 2011. ISSN 1434-8411.
- HIGHAM, N. J. *Accuracy and Stability of Numerical Algorithms*. Second. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 2002. xxx+680 p. ISBN 0-89871-521-0.
- HOAI-PHUONG, N. T.; TUY, H. A unified monotonic approach to generalized linear fractional programming. *J. Global Optimization*, v. 26, n. 3, p. 229–259, 2003. Disponível em: <<http://dblp.uni-trier.de/db/journals/jgo/jgo26.html#Hoai-PhuongT03>>.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *IEEE International Conference on Neural Networks, 1995. Proceedings*. Perth, WA: IEEE Press, 1995. v. 4, p. 1942–1948 vol.4.
- LEE, J.-W.; MAZUMDAR, R.; SHROFF, N. Downlink power allocation for multi-class wireless systems. *Networking, IEEE/ACM Transactions on*, IEEE, v. 13, n. 4, p. 854–867, Aug 2005. ISSN 1063-6692.
- MARQUES, M. de P.; ADANIYA, M. H.; SAMPAIO, L. H. D.; ABRAO, T.; JESZENSKY, P. J. E. Ant colony optimization for resource allocation and anomaly detection in communication networks. In: ABRÃO, T. (Ed.). *Search Algorithms*. Rijeka, Croatia: InTech Open, ISBN: 980-953-307-672-5, 2012. cap. 5, p. 109–142.

- MELLA, S.; GHIMIRE, B.; REED, C. M.; HAAS, H. Energy efficient resource allocation in ofdma networks using ant colony optimization. In: *ISCIT'12 - Proc. International Symposium on Communications and Information Technologies*. Gold Coast, Australia: IEEE, 2012. p. 1–5.
- MOUSTAFA, M.; HABIB, I.; NAGHSHINEH, M. Wireless resource management using genetic algorithm for mobiles equilibrium. *Computer Networks*, v. 37, n. 5, p. 631 – 643, 2001. ISSN 1389-1286. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S138912860100233X>>.
- MYERSON, R. B. *Game theory - Analysis of Conflict*. Harvard: Harvard University Press, 1997. I-XIII, 1-568 p. ISBN 978-0-674-34116-6.
- OLIVEIRA, L. D.; CIRIACO, F.; JESZENSKY, P. J. E.; ABRAO, T. Particle swarm and quantum particle swarm optimization applied to ds/cdma multiuser detection in flat rayleigh channels. *IEE (Ed.). ISSST'06 - Ninth International Symposium on Spread Spectrum Techniques and Applications*. Manaus, Brasil., p. 133–137, 2006.
- PALOMAR, D. P.; FONOLLOSA, J. R. Practical algorithms for a family of waterfilling solutions. *IEEE Transactions on Signal Processing*, v. 53, n. 2-1, p. 686–695, 2005.
- PROAKIS, J. G. *Digital Communications*. 4th. ed. New York: McGraw- Hill, 2000.
- QIAN, L. M.; ZHANG, Y. J.; HUANG, J. Mapel: Achieving global optimality for a non-convex wireless power control problem. *CoRR*, abs/0805.2675, 2008. Disponível em: <<http://dblp.uni-trier.de/db/journals/corr/corr0805.html#abs-0805-2675>>.
- SAMPAIO, L. D. H.; LIMA, M. F.; ZARPELAO, B. B.; Proenca Jr., M. L.; ABRAO, T. Swarm power-rate optimization in multi-class services ds/cdma networks. In: *XXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. Gramado, RS: SBRC, 2010. p. 615–628.
- SARAYDAR, C.; MANDAYAM, N. B.; GOODMAN, D. Efficient power control via pricing in wireless data networks. *Communications, IEEE Transactions on*, v. 50, n. 2, p. 291–303, Feb 2002. ISSN 0090-6778.
- SCHAIBLE, S. Minimization of ratios. *Journal of Optimization Theory and Applications*, Springer Netherlands, v. 19, p. 347–352, 1976. ISSN 0022-3239. 10.1007/BF00934101.
- SCHAIBLE, S.; IBARAKI, T. Fractional programming. *European Journal of Operational Research*, v. 12, n. 4, p. 325 – 338, 1983. ISSN 0377-2217.
- SENETA, E. *Non-Negative Matrices and Markov Chains*. Sydney, Australia: Springer, 2006.
- SHANNON, C. E. The mathematical theory of communication. *The Bell System Technical Journal*, v. 27, n. (reprinted with corrections 1998), p. 379–423, 623–656, July, October 1948.

- SOCHA, K.; DORIGO, M. Ant colony optimization for continuous domains. In: *European Journal of Operational Research*. Brussels, Belgium: Elsevier, 2008. p. 1155–1173.
- SORENSEN, L. *Introduction to the Practice of Statistics*. New York, NY: W. H. Freeman and Company, 2006. 43-47 p. ISBN 0-7167-6363-X.
- STUBER, G. L. *Principles of Mobile Communication*. 1st. ed. Norwell, MA, USA: Kluwer Academic Publishers, 1996. ISBN 0792397320.
- TSE, D.; VISWANATH, P. *Fundamentals of wireless communication*. New York, NY, USA: Cambridge University Press, 2005. ISBN 0-5218-4527-0.
- ZAPPONE, A.; BUZZI, S.; JORSWIECK, E. A. Energy-efficient power control and receiver design in relay-assisted ds/cdma wireless networks via game theory. *IEEE Communications Letters*, v. 15, n. 7, p. 701–703, 2011. Disponível em: <<http://dblp.uni-trier.de/db/journals/icl/icl15.html#ZapponeBJ11>>.
- ZHANG, Z.; ZHANG, H.; ZHAO, Z.; LIU, H.; WEN, X.; JING, W. Low complexity energy-efficient resource allocation in down-link dense femtocell networks. In: *Personal Indoor and Mobile Radio Communications (PIMRC), 2013 IEEE 24th International Symposium on*. London, UK: IEEE, 2013. p. 1650–1654. ISSN 2166-9570.
- ZIELINSKI, K.; WEITKEMPER, P.; LAUR, R.; KAMMEYER, K. D. Optimization of power allocation for interference cancellation with particle swarm optimization. *Evolutionary Computation, IEEE Transactions on*, v. 13, n. 1, p. 128–150, Feb 2009. ISSN 1089-778X.

Apêndice A – Prova da quase-concavidade da equação 2.30

A equação (2.30) pode ser reescrita como:

$$\eta_{\mathbb{E}}(\mathbf{p}) = K \cdot \frac{\sum_{i=1}^U [\bar{f}_i(\mathbf{p}) - \bar{h}_i(\mathbf{p})]}{\sum_{i=1}^U p_i + P_c} \quad (\text{A.1})$$

Lema A.0.1. (*Preservação da concavidade na adição*) Considere $h : \mathbb{R}_+ \rightarrow \mathbb{R}_+$ tal que $h(x) = f(x) + g(x)$, com $f, g : \mathbb{R}_+ \rightarrow \mathbb{R}_+$. Se $f(x)$ e $g(x)$ são funções côncavas, então $h(x)$ é côncava [Grant e Boyd 2008].

Demonstração. Considere $t \in [0, 1]$ e $x < y$. A partir da definição de h segue que:

$$h(tx + (1-t)y) = f(tx + (1-t)y) + g(tx + (1-t)y)$$

A partir da concavidade de f e g , e da Desigualdade de Jensen [Grant e Boyd 2008]:

$$\begin{aligned} f(tx + (1-t)y) + g(tx + (1-t)y) &\geq \\ tf(x) + (1-t)f(y) + tg(x) + (1-t)g(y) \end{aligned}$$

$$\begin{aligned} f(tx + (1-t)y) + g(tx + (1-t)y) &\geq \\ t[f(x) + g(x)] + (1-t)[f(y) + g(y)] \end{aligned} \quad (\text{A.2})$$

$$\begin{aligned} h(tx + (1-t)y) &\geq \\ th(x) + (1-t)h(y) \end{aligned}$$

que é a condição necessária para a concavidade de h .

□

Lema A.0.2. (Concavidade de $\log_2(a\delta + b)$). Considere $a\delta + b$ como sendo uma função afim estritamente crescente. Então, $\log_2(a\delta + b)$ é côncavo em $\delta \geq 0$.

Demonstração. Uma vez que $\log_2(\cdot)$ é uma função contínua e diferenciável no intervalo $[0, \infty)$, sua segunda derivada é:

$$(\log_2(a\delta + b))'' = \frac{-a^2}{\ln(2)(a\delta + b)^2} \quad (\text{A.3})$$

está claro que $(\log_2(a\delta + b))'' \leq 0$ e portanto $\log_2(a\delta + b)$ é côncava em $\delta \geq 0$ para qualquer $a, b \in \mathbb{R}$. \square

É evidente que o denominador é de fato uma função afim. O numerador, por outro lado, é uma diferença entre funções logarítmicas. De acordo com o Lemma A.0.2, $\bar{f}_i(\mathbf{p})$ e $\bar{h}_i(\mathbf{p})$ são funções côncavas, portanto, $\bar{f}_i(\mathbf{p}) - \bar{h}_i(\mathbf{p})$ também é côncava, e $\sum_{i=1}^U \bar{f}_i(\mathbf{p}) - \bar{h}_i(\mathbf{p})$ é côncava. Note que o denominador na Eq. (2.30) é o somatório de funções lineares, portanto é afim. Dado que $J_3(\mathbf{p})$ é uma função do tipo $f(x) = \alpha g(x)/h(x)$, se $g(\delta)$ é côncava e $h(\delta)$ é afim, então $f(\delta)$ é quase-côncava [Avriel et al. 2010, Table 5.5], o que é verdade uma vez que $\sum_{i=1}^U \bar{f}_i(\mathbf{p}) - \bar{h}_i(\mathbf{p})$ é côncava e $\sum_{i=1}^U p_i + P_c$ é afim.