

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO ASSOCIADO, EM  
ENGENHARIA ELÉTRICA

CRISTIANE APARECIDA PENDEZA MARTINEZ

MÉTODOS DE OTIMIZAÇÃO PARA ALOCAÇÃO DE  
RECURSOS EM REDES OCDMA

TESE

CORNÉLIO PROCÓPIO

2020

CRISTIANE APARECIDA PENDEZA MARTINEZ

**MÉTODOS DE OTIMIZAÇÃO PARA ALOCAÇÃO DE  
RECURSOS EM REDES OCDMA**

Tese apresentada ao Programa de Pós-Graduação Associado, em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Doutor em Engenharia Elétrica” – Área de Concentração: Sistemas Eletrônicos.

Orientador: Prof. Dr. Taufik Abrão

**CORNÉLIO PROCÓPIO**

**2020**

---

### Dados Internacionais de Catalogação na Publicação

---

M385     Martinez, Cristiane Aparecida Pendeza

Métodos de otimização para alocação de recursos em rede OCDMA / Cristiane Aparecida Pendeza Martinez. – 2020.  
165 f. : il. color. ; 31 cm.

Orientador: Taufik Abrão.

Tese (Doutorado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação Associado em Engenharia Elétrica. Cornélio Procópio, 2020.

Bibliografia: p. 159-165.

1. Otimização matemática. 2. Programação não-linear. 3. Redes neurais (Computação). 4. Controladores elétricos. 5. Engenharia Elétrica – Teses. I. Abrão, Taufik, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação Associado em Engenharia Elétrica. III. Título.

CDD (22. ed.) 621.3

---

### Biblioteca da UTFPR - Câmpus Cornélio Procópio

Bibliotecário/Documentalista responsável:  
Romeu Righetti de Araujo – CRB-9/1676

## TERMO DE APROVAÇÃO

Título da Tese N° 002:

**“Métodos de Otimização para Alocação de Recursos em Redes OCDMA”.**

por

**Cristiane Aparecida Pendeza Martinez**

Orientador: Prof. Dr. Taufik Abrão  
Coorientador:

Esta tese foi apresentada como requisito parcial à obtenção do grau de DOUTOR EM ENGENHARIA ELÉTRICA – Área de Concentração: Sistemas Eletrônicos, pelo Programa de Pós-Graduação Associado em Engenharia Elétrica – PPGAEE – da Universidade Tecnológica Federal do Paraná – UTFPR – Câmpus Cornélio Procópio, às 09h30 do dia 17 de julho de 2020. O trabalho foi \_\_\_\_\_ pela Banca Examinadora, composta pelos professores:

\_\_\_\_\_  
Prof. Dr. Taufik Abrão  
Presidente  
UEL

\_\_\_\_\_  
Prof. Dr. Marcelo Luís Abbade  
UNESP

\_\_\_\_\_  
Prof. Dr. José Roberto Amazonas  
UPC - Espanha

\_\_\_\_\_  
Prof. Dr. José Carlos Marinello Filho  
UTFPR-CP

\_\_\_\_\_  
Prof. Dr. Paulo Rogério Scalassara  
UTFPR-CP

Visto da coordenação:

\_\_\_\_\_  
Prof. Dr. Sérgio Augusto Oliveira da Silva  
Coordenador do Programa de Pós-Graduação Associado em  
Engenharia Elétrica  
UTFPR Câmpus Cornélio Procópio

A Folha de Aprovação assinada encontra-se na Coordenação do Programa.

## AGRADECIMENTOS

Esta fase da minha vida é muito especial e não posso deixar de agradecer a Deus por toda força, ânimo e coragem que me ofereceu para ter alcançado minha meta.

Agradeço à minha família, à minha mãe e ao meu pai, onde quer que ele esteja, os quais são para mim exemplo de força, coragem e amor sempre presentes em toda minha existência. Agradeço, especialmente, ao meu marido e companheiro André, a quem admiro, meu eterno agradecimento por compreender todos os meus momentos e dificuldades sempre pronto em me ajudar, e aos meus filhos Miguel e Isabela, que são os maiores presentes que Deus poderia ter me dado nesta vida. Por toda felicidade, amor, compreensão, apoio, incentivo e dedicação, encontrados na minha querida família.

Ao Prof. Dr. Fábio Renan Durand (*in memoriam*), que foi meu orientador por dois anos, pela confiança em mim depositada. Agradeço pela oportunidade, não só por sua orientação mas também pelo aprendizado com sua sabedoria, competência, determinação, amizade, força e coragem que, para mim, sempre foram uma inspiração para continuar e acreditar.

Ao Prof. Dr. Taufik Abrão, pelo apoio e disponibilidade em prosseguir com a orientação deste trabalho, pelo qual tenho muita estima e admiração e me propiciou um grande aprendizado. É um grande prazer trabalhar ao seu lado.

Aos meus colegas de estudo, e em particular, aos professores do Cipeca, pela confiança, incentivo e apoio em todos os momentos. Em especial ao Layhon, agradeço pelo apoio e amizade.

Ao departamento acadêmico de Matemática da UTFPR-CP, por ter concedido afastamento parcial, que foi imprescindível na realização deste trabalho.

“Aqueles que passam por nós, não vão sós, não nos deixam sós.  
Deixam um pouco de si, levam um pouco de nós.”

(Antoine de Saint-Exupéry)

## RESUMO

PENDEZA MARTINEZ, Cristiane Aparecida. MÉTODOS DE OTIMIZAÇÃO PARA ALOCAÇÃO DE RECURSOS EM REDES OCDMA. 167 f. Tese – Programa de Pós-Graduação Associado, em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

Esta Tese trata de um estudo sobre alocação de recursos em redes de acesso múltiplo por divisão de código óptico e tem por objetivo analisar técnicas de otimização para resolução de três problemas de alocação de recursos: o problema de alocação de potência mínima, o problema de maximização da eficiência energética e o problema do compromisso entre eficiência energética e eficiência espectral. Para o problema de alocação de potência mínima, propomos a implementação da abordagem da rede neural artificial de Hopfield modificada e também o uso de métodos de programação não linear como programação quadrática sequencial e o método Lagrangiano aumentado, os quais são comparados em desempenho-complexidade, robustez algorítmica e qualidade da solução. Para o problema de maximização da eficiência energética em redes de acesso múltiplo por divisão de código óptico, foram propostos e analisados quatro métodos de programação não linear: o método Lagrangiano aumentado, o método de programação quadrática sequencial, a técnica de majoração-minimização e o método de Dinkelbach. Todos os métodos utilizados foram capazes de alcançar convergência para a solução adequada do problema. No entanto, em algumas configurações específicas, porém realistas, do sistema de comunicação de acesso múltiplo por divisão de código óptico com número elevado de usuários, o método Dinkelbach é ineficiente em termos de convergência total. Outra estratégia para a resolução do problema de maximização da eficiência energética propõe a combinação do método Lagrangiano aumentado com métodos heurísticos evolutivos, a saber otimização por enxame de partículas e uma hibridação do enxame de partículas com o algoritmo de busca gravitacional e com um método de otimização do tipo Quase-Newton. A estrutura do método do Lagrangiano aumentado permite um melhor ajuste ao problema e, por fim, fornece mais informações sobre a solução. Para o problema do compromisso entre eficiência energética e eficiência espectral denominada eficiência de recursos, duas técnicas de otimização multiobjetivo foram utilizadas, o método da soma de pesos e método  $\epsilon$ -restrito, ambas associadas ao método do Lagrangiano aumentado, o qual foi empregado na resolução dos subproblemas gerados. Como resultado, a qualidade da solução no sentido do limite de Pareto foi verificada.

**Palavras-chave:** Otimização não-linear, Redes ópticas, Controle de Potência, Eficiência Energética, Rede neural de Hopfield modificada, Compromisso EE-SE, Otimização multiobjetivo

## ABSTRACT

PENDEZA MARTINEZ, Cristiane Aparecida. OPTIMIZATION METHODS FOR PROBLEMS OF RESOURCE ALLOCATION IN OCDMA NETWORKS. 167 f. Tese – Programa de Pós-Graduação Associado, em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

This thesis deals with a study on resource allocation in optical code division multiple access networks and aims to analyze optimization techniques for solving three resource allocation problems: the minimum power allocation problem, the problem of maximizing energy efficiency and the spectral-energy efficiency tradeoff problem. For the minimum power allocation problem, we propose the implementation of the modified Hopfield artificial neural network approach and also the use of nonlinear programming methods such as sequential quadratic programming and the augmented Lagrangian method, which are compared in performance-complexity, algorithmic robustness and quality of the solution. For the problem of maximizing energy efficiency in optical code division multiple access, four non-linear programming methods were proposed and analyzed: the augmented Lagrangian method, the sequential quadratic programming method, the majoration-minimization technique and the Dinkelbach method. All the methods used were able to achieve convergence for the adequate solution of the problem. However, in some specific yet realistic configurations of the multiple access communication system with a high number of users, the Dinkelbach method is inefficient in terms of full convergence. Another proposed strategy for solving the problem of maximizing energy efficiency combines the augmented Lagrangian with evolutionary heuristic methods, namely optimization by particle swarm, as well as the hybridization of the particle swarming technique with the gravitational search algorithm, also combined with the Quasi-Newton method. The structure of the augmented Lagrangian optimization allows a better adjustment to the problem while providing, more information about the solution. For the problem of the energy-spectral efficiencies tradeoff, namely resource efficiency, two multiobjective optimization techniques were used, the weight sum method and the  $\epsilon$ -restricted method, both associated with the augmented Lagrangian method, which was employed in solving the generated subproblems. As a result, the quality of the solution towards the Pareto limit was checked.

**Keywords:** Nonlinear Optimization, Optical Networks, Power Control, Energy Efficiency, Modified Hopfield neural network, tradeoff EE-SE, Multiobjective Optimization



## LISTA DE FIGURAS

FIGURA 1	– Arquitetura OCDMA-PON. ....	33
FIGURA 2	– OLT para OCDMA-PON. ....	33
FIGURA 3	– ONU para OCDMA-PON. ....	34
FIGURA 4	– Esquema da transmissão óptica. ....	38
FIGURA 5	– Rede de Hopfield. ....	52
FIGURA 6	– Rede mH-NN para resolução de problemas de otimização com restrições. ....	56
FIGURA 7	– Rede mH-NN para resolução do problema de minimização da potência em redes OCDMA. ....	60
FIGURA 8	– Evolução dos níveis individuais de potência até o equilíbrio no Cenário A considerando $K = 8$ usuários: a) ALM; b) SQP; c) mH-NN algoritmos. ....	70
FIGURA 9	– Soma da potência (a) e soma das taxas (b) alocação através das iterações para $K = 8, 16$ e $32$ usuários no Cenário A. ....	71
FIGURA 10	– Níveis de soma de potências para $K = 48, 64$ e $128$ usuários e diferentes $\Gamma^* \in [17, 20, 22]$ dB. ....	76
FIGURA 11	– Alocação de soma das taxas para $K = 48; 64$ e $128$ usuários (cenário B) com diferentes CINR alvos: a) $\Gamma^* = 17$ dB; b) $\Gamma^* = 20$ dB, e c) $\Gamma^* = 22$ dB. ....	77
FIGURA 12	– Evolução da NMSE dos métodos em relação ao vetor potência $\mathbf{p}^*$ para $K = [8, 16, 32]$ usuários. ....	78
FIGURA 13	– Tempo de Execução para os três métodos considerando $K = \{8, 16, 32, 64, 128\}$ usuários e nível de QoS de $20$ dB. ....	79
FIGURA 14	– Soma da potência alocada pelos algoritmos SQP, mH-NN e ALM em tempo real, aumentando o número de usuários em $400\%$ . ....	81
FIGURA 15	– Ilustração da função de perturbação $p_i[n]$ (59) $\times$ número de iterações $n$ com $p_i^o = 0, 1$ W, e respectiva convergência de alocação de potência por ONU considerando uma perturbação inserida em $2 \leq n \leq 7$ iteração para os métodos mH-NN, SQP e ALM. ....	83
FIGURA 16	– $\max \Gamma_i$ para: a) sob <i>on fly</i> aumentando o número de usuários em $400\%$ ; b) considerando uma inserção de perturbação em $2 \leq n \leq 7$ iteração. ....	84
FIGURA 17	– Uma ilustração gráfica dos dois passos da técnica MaMi. ....	94
FIGURA 18	– Convergência para o problema EE-OCDMA no Cenário A e considerando diferentes métodos de otimização e número de usuários $K \in \{8; 16; 32\}$ . ....	101
FIGURA 19	– Convergência para EE total das três classes de serviço CLASSE 1, CLASSE 2 e CLASSE 3 e número de usuários $K \in \{8; 16; 32\}$ . ....	102
FIGURA 20	– Evolução do número total de avaliação de funções dos métodos testados para $K = [8, 16, 32]$ usuários. ....	103
FIGURA 21	– Evolução do somatório da potência de ALM-EE, MaMi-EE e SQP-EE quanto ao número de iterações. ....	104

FIGURA 22 – Convergência dos níveis individuais de potência para ALM, MAMI e SQP considerando $K = 32 \in \{U^{\text{CLASSE } 1}; U^{\text{CLASSE } 2}, U^{\text{CLASSE } 3}\} \equiv [24; 4; 4]$ usuários. ....	105
FIGURA 23 – Taxas mínimas atingidas para $K = 32 \in \{U^{\text{CLASSE } 1}; U^{\text{CLASSE } 2}, U^{\text{CLASSE } 3}\} \equiv [24; 4; 4]$ usuários após convergência. ....	106
FIGURA 24 – Tempo computacional $\times$ número de nós OCDMA para os métodos PNL de otimização: a) Cenário A; b) Cenário B. ....	108
FIGURA 25 – Convergência para o problema de EE e considerando diferentes métodos de otimização e número de usuários $K \in \{32; 64; 128; 256\}$ . .	125
FIGURA 26 – Curvas de EE para $p_2^*, \dots, p_k^*$ fixos e $p_1$ variando. Comportamento Fracional de $J_2$ . ....	126
FIGURA 27 – FLOPs consumidos aumentando com o número de nós para os três métodos de otimização de EE-OCDMA. ....	127
FIGURA 28 – Evolução da potência alocada <i>versus</i> iterações para os métodos ALM-PSO, ALM-PSOGSA e ALM-BFGS. Recurso de Potência Total de $P_T = 800\text{mW}$ . ....	127
FIGURA 29 – Convergência de níveis de potência individuais para ALM-PSO, ALM-PSOGSA e ALM-BFGS, considerando $K = 32 \in \{U^{\text{CLASSE } 1}; U^{\text{CLASSE } 2}, U^{\text{CLASSE } 3}\} \equiv [24; 4; 4]$ usuários. ....	128
FIGURA 30 – Taxas mínimas e alcançáveis para $K = 32 \in \{U^{\text{CLASSE } 1}; U^{\text{CLASSE } 2}, U^{\text{CLASSE } 3}\} \equiv [24; 4; 4]$ usuários após a convergência ....	129
FIGURA 31 – Fronteira de Pareto para o problema EE-SE OCDMA obtida pelos métodos WS e $\epsilon$ -C para $K \in \{8; 16; 32\}$ usuários. Fronteira de Pareto obtida pelo método de Busca Exaustiva é representado para o cenário com $K = 8$ usuários. ....	148
FIGURA 32 – Evolução do número total de avaliação de funções dos métodos testados para $K = [8, 16, 32]$ usuários. ....	149
FIGURA 33 – Relação EE-SE destacando o ponto de EE máximo e SE máximo para o recurso de potência disponível. ....	151
FIGURA 34 – Fronteira de Pareto obtidas pelos métodos WS-ALM, WS-SQP, $\epsilon$ -C-ALM e $\epsilon$ -C-SQP por $K \in \{8; 16; 32\}$ usuários. Além disso, para $K = 8$ usuários, as Fronteira de Pareto são obtidas pelo método de Busca Exaustiva. ....	152
FIGURA 35 – Evolução da soma de potências para ambos os métodos de MOO considerando $K \in \{8, 16, 32\}$ usuários. ....	153
FIGURA 36 – Impacto do fator de peso $\lambda$ e a restrição $\epsilon$ no compromisso EE-SE considerando os métodos WS e $\epsilon$ -C, respectivamente. ....	154
FIGURA 37 – Variação de EE para diferentes níveis máximos de potência. ....	154
FIGURA 38 – Desempenho de EE e max-SE em relação à potência disponível máxima $p_{\text{max}}$ para $K = 8, 16$ e $32$ usuários. ....	156
FIGURA 39 – Evolução do número total de avaliação de funções dos métodos testados para $K = [8, 16, 32]$ usuários. ....	156

## LISTA DE TABELAS

TABELA 1	– Valores de parâmetros adotados. ....	67
TABELA 2	– Tempo de execução, número de iterações externas para convergência, factibilidade para os três algoritmos, FLOPS, NMSE e soma das taxas considerando o aumento do número de nós ópticos. ....	68
TABELA 3	– Classe I– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para $K = 48, 64, 128$ nós ópticos. ....	73
TABELA 4	– Classe II– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para $K = 48, 64, 128$ nós ópticos. ....	74
TABELA 5	– Classe III– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para $K = 48, 64, 128$ nós ópticos. ....	74
TABELA 6	– Robustez dos algoritmos ALM, SQP e mH-NN para o problema de alocação de potência em (23) sobre $\mathcal{T} = 100$ realizações, considerando o nível de QoS de 22dB. ....	79
TABELA 7	– Classe C – Soma de potência e factibilidade atingível a partir de (25) para aumentar o número de nós ópticos. ....	80
TABELA 8	– Valores de parâmetros adotados. ....	98
TABELA 9	– Tempo de execução, valores de EE atingíveis, número de iterações para convergência e optimalidade para os algoritmos EE-OCDMA, considerando o aumento do número de nós ópticos. ....	100
TABELA 10	– Tempo de execução, valor EE atingível, número de iterações para convergência, número de avaliações de funções e optimalidade para os algoritmos EE-OCDMA considerando Três classes de serviços (Cenário B) e número crescente de nós ópticos. ....	102
TABELA 11	– Parâmetros da rede adotados ....	122
TABELA 12	– Parâmetros adotados de entrada de algoritmo ....	122
TABELA 13	– Tempo de execução, valor EE atingível, número de iterações para convergência, factibilidade e optimalidade para os algoritmos EE-OCDMA, considerando o aumento do número de nós ópticos ....	123
TABELA 14	– Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO. ....	130
TABELA 15	– Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO. ....	130
TABELA 16	– Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSOGSA. ....	130
TABELA 17	– Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSOGSA. ....	131
TABELA 18	– Tempo de execução, valor EE atingível, número de iterações para convergência, factibilidade e optimalidade para os algoritmos EE-OCDMA,	

	considerando o aumento do número de nós ópticos .....	131
TABELA 19 –	Valores de parâmetros de entrada adotados para os algoritmos RE- OCDMA propostos. ....	143
TABELA 20 –	Valores de parâmetros adotados. ....	145
TABELA 21 –	Tempo de execução, número de sucessos de convergência, número de soluções distintas na fronteira de Pareto, NMSE e número de avaliação de função para os algoritmos EE-SE OCDMA considerando o aumento de nós ópticos no Cenário A. ....	146
TABELA 22 –	Figura de mérito adotada para avaliar o desempenho dos algoritmos EE-SE OCDMA considerando o aumento do número de nós ópticos $K = 8, 16$ e $32$ usuários multi-taxa no cenário B. ....	150

## LISTA DE SIGLAS

ADP	Fotodiodo de Avalanche ( <i>Avalanche Photodiode</i> )
ALM	Método Lagrangiano Aumentado ( <i>Augmented Lagrangian method</i> )
AWGN	Ruído Aditivo Gaussiano Branco ( <i>Additive White Gaussian Noise</i> )
BER	Taxa de Erro de Bit ( <i>Bit Error Rate</i> )
BFGS	Método quase-Newton definido por Broyden-Fletcher-Goldfarb-Shanno
CDMA	Acesso Múltiplo por Divisão de Código ( <i>Code Division Multiple Access</i> )
CINR	Relação entre a Potências da Portadora e a Potência de Ruído mais Interferência ( <i>Carrier-to-Interference plus Noise Ratio</i> )
CO	Escritório Central ( <i>Central Office</i> )
CvX	Programação Convexa Disciplinada ( <i>Disciplined Convex Programming</i> )
DK	Método de Dinkelbach ( <i>Dinkelbach's method</i> )
EDFA	Amplificador de Fibra Dopada com Érbio ( <i>Erbium Doped Fibre Amplifier</i> )
EE	Eficiência Energética ( <i>Energy Efficiency</i> )
E/O	Elétrico/Óptico
$\epsilon$ -C	Método do $\epsilon$ -Restrito ( <i><math>\epsilon</math>-Constraint Method</i> )
ES	Busca Exaustiva ( <i>Exhaustive search</i> )
EWHP	Códigos Primos de Salto de Comprimento de Onda Estendido ( <i>Extended Wavelength-Hopping Prime Codes</i> )
FLOPS	Operações de Ponto Flutuante por Segundo ( <i>Floating-Point Operations Per Second</i> )
GSA	Algoritmo de Busca Gravitacional ( <i>Gravitational Search Algorithm</i> )
MAI	Interferência de Acesso Múltiplo ( <i>Multiple Access Interference</i> )
MaMi	Majoração-Minimização ( <i>Majorization-Minimization</i> )
MAN	Redes Metropolitana ( <i>Metropolitan Area Networks</i> )
mH-NN	Rede Neural de Hopfield Modificada ( <i>Modified Hopfield Neural Network</i> )
MLEWHP	Códigos Primos de Salto de Comprimento de Onda Estendido de Múltiplos Comprimentos ( <i>Multiple-length Extended Wavelength-hopping Prime Codes</i> )
MOO	Problema de Otimização Multiobjetivo ( <i>Multiobjective Optimization</i> )
NG-PON	Redes Ópticas Passivas de Próxima Geração ( <i>Next-Generation Passive Optical Network</i> )
NMSE	Erro Quadrático Médio Normalizado ( <i>Normalized Mean Square Error</i> )
OCDMA	Acesso Múltiplo por Divisão de Código em Domínio Óptico ( <i>Optical Code Division Multiple Access</i> )
OFDMA	Acesso Múltiplo por Divisão de Frequência Ortogonal ( <i>Orthogonal Frequency Division Multiple Access</i> )
OLT	Terminal de Linha Óptica ( <i>Optical Line Termina</i> )
ONU	Unidade de Rede Óptica ( <i>Optical Network Unit</i> )
PIIN	Ruído de Intensidade Induzida por Fase ( <i>Phase-Induced Intensity Noise</i> )
PIN	Positivo Intrínseco Negativo ( <i>Positive Intrinsic Negative</i> )
PSK	Modulação por deslocamento de fase ( <i>Phase-Shift Keying</i> )
PNL	Programação Não Linear

PON	Redes Ópticas Passivas ( <i>Passive Optical Networks</i> )
PSO	Otimização por Enxame de Partículas ( <i>Particle swarm optimization</i> )
QoS	Qualidade de Serviço ( <i>Quality of Service</i> )
RE	Eficiência de Recursos ( <i>Resource Efficiency</i> )
RN	Nó Remoto ( <i>Remote Node</i> )
RNA	Rede Neural Artificial
SDD	Detecção Direta Espectral ( <i>Direct Detection Spectral</i> )
SE	Eficiência Espectral ( <i>Spectral Efficiency</i> )
SINR	Relação Sinal-Ruído mais Interferência ( <i>Signal to Interference plus Noise Ratio</i> )
SQP	Programação Quadrática Sequencial ( <i>Quadratic Sequential Programming</i> )
SSFBG	Grade de Bragg de Fibra Superestruturada ( <i>Super-Structured Fiber Bragg Grating</i> )
WAN	Redes de alcance amplo ( <i>Wide Area Networks</i> )
WDM	Multiplexação por Divisão de Comprimento de Onda ( <i>Wavelength Division Multiplexing</i> )
WS	Método da Soma Ponderada ( <i>Weighted Sum Method</i> )
ZCCC	Código de Correlação Cruzada Zero ( <i>Zero Cross Correlation Code</i> )

## LISTA DE SÍMBOLOS

$a_k$	Tamanho do passo na $k$ -ésima iteração na direção de busca dos métodos SQP e BFGS
$ac_i(\cdot)$	Aceleração do agente $i$ na iteração $k$ no método GSA
$\mathcal{A}_\rho(\cdot)$	Função Lagrangiana aumentada
$\text{BER}_i$	Taxa de erro de bit tolerável para o $i$ -ésimo usuário
$\beta$	Fator de ponderação da métrica $\eta_{RE}$
$c'_i$	Coefficiente de confiança da partícula nela mesma
$c'_2$	Coefficiente de confiança da partícula em relação as outras partículas
$\text{cS}$	Sucesso de convergência
$\gamma_i$	SNIR do $i$ -ésimo usuário
$\gamma_i^*$	SINR alvo do $i$ -ésimo usuário
$\Gamma_i$	CINR do $i$ -ésimo usuário
$\Gamma^*$	CINR alvo do $i$ -ésimo usuário
$\Gamma^+(\cdot)$	Função obtida transformando a restrição de desigualdade da CINR em uma restrição de igualdade
$\mathbf{d}^k$	Direção de busca na $k$ -ésima iteração dos métodos SQP e BFGS
$\Delta t$	Tamanho do passo na direção de busca no método mH-NN
$\Delta v$	Direção de optimalidade no método mH-NN
$E(\cdot)$	Função de energia no método mH-NN
$E^{conf}(\cdot)$	Função que confina todas as restrições no método mH-NN
$E^{ot}(\cdot)$	Função de energia a ser otimizada no método mH-NN
$E_k^{rest}(\cdot)$	Funções que representam as $k$ -ésimas restrições do problema no método mH-NN
$\mathbb{E}[\cdot]$	Operador esperança
$\text{erfc}(\cdot)$	Função de erro complementar
$\epsilon$	Limitante inferior da restrição (C. $\epsilon$ ) do método $\epsilon$ -C
$\epsilon_k$	Parâmetro de tolerância do $k$ -ésimo subproblema do ALM
$f(\cdot)$	Função custo em um PNL
$F$	Ganho de processamento
$F_i$	Ganho de processamento do $i$ -ésimo usuário
$\mathcal{F}^k$	Factibilidade na iteração $k$ para os métodos de otimização
$F_{ij}(\cdot)$	Forças gravitacionais do agente $j$ no agente $i$ no método GSA
$\zeta$	Tolerância de convergência dos métodos analisados
$\bar{g}(\cdot)$	Função de ativação no método mH-NN
$\mathbf{g}(\cdot)$	Função vetorial que representa as restrições de desigualdade em um PNL
$g_{best}$	Melhor posição assumida pelo enxame até a iteração $k$ nas meta-heurísticas
$\mathbf{G}$	Matriz de atenuação da fibra que conecta todos os pares transceptores
$G_{ii}$	Atenuação do sinal do caminho do código óptico
$G_{ij}$	Atenuação entre o $j$ -ésimo nó transmissor e o $i$ -ésimo nó receptor $i$
$G$	Constante gravitacional no método GSA
$\eta$	Fator de decaimento passivo no método de Hopfield no método mH-NN

$\eta_{EE}$	Eficiência energética
$\eta_{SE}$	Eficiência espectral
$\mathbf{h}(\cdot)$	Função vetorial que representa as restrições de igualdade em um PNL
$\mathbf{H}$	Matriz de interferência normalizada
$H_{ij}$	$ij$ -ésimo elemento da matriz de interferência normalizada
$\theta_i$	Gap entre as taxas de informação teórica e real do $i$ -ésimo usuário
$\Theta$	Optimalidade nos métodos de PNLs
$\mathcal{I}$	Número máximo de iterações
$\iota$	Eficiência de energia do transponder
$\boldsymbol{\iota}^b$	Vetor de <i>bias</i> associado à função de energia da rede no método mH-NN
$\boldsymbol{\iota}_j^b$	Limiar ( <i>bias</i> ) aplicado ao $j$ -ésimo neurônio no método mH-NN
$\boldsymbol{\iota}^{conf}$	Vetor de <i>bias</i> associado a $E^{conf}$ no método mH-NN
$\boldsymbol{\iota}^{ot}$	Vetor de <i>bias</i> associado a $E^{ot}$ no método mH-NN
$J_1(\cdot)$	Função custo para o controle de potência
$J_2(\cdot)$	Função custo para a eficiência energética
$J_1^+(\cdot)$	Função $J_1$ redefinida
$K$	Número de dimensões do problema (usuários)
$K_v$	Denota o número de usuários da classe de serviço $v$
$\mathcal{L}(\cdot)$	Função Lagrangiana
$\lambda$	Fator de ponderação entre $\eta_{EE}$ e $\eta_{SE}$ no método WS
$\lambda_a$	Número inteiro não negativo que representa a restrição na autocorrelação de códigos 2D
$\lambda_c$	Número inteiro não negativo que representa a restrição na correlação de códigos 2D
$\lambda_{max}$	Maior autovalor da matriz $\mathbf{H}$
$\Lambda^*$	Matriz diagonal com $\Gamma^*$ alvo como seus elementos
$M$	Ordem de modulação
$\mu_i$	Multiplicador de Lagrange para a $i$ -ésima equação de restrição de desigualdade no ALM
$\mu_i^k$	Multiplicador de Lagrange para a $i$ -ésima equação de restrição de desigualdade na $k$ -ésima iteração nos métodos SQP e ALM
$M_{aj}$	Massa gravitacional ativa relacionada agente $j$ no método GSA
$M_{pi}$	Massa gravitacional passiva relacionada ao agente $i$ no método GSA
$N_T$	Número de comprimento de ondas disponíveis
$N_\lambda$	Comprimento dos códigos 2D
$\nu$	Representa o incremento aplicado em $\rho$ no ALM
$\mathbf{p}$	Potência óptica de transmissão
$p_i$	Potência de transmissão do $i$ -ésimo usuário
$p_{min}$	Potência óptica mínima de transmissão
$p_{max}$	Potência óptica máxima de transmissão
$\mathbf{p}^+$	Vetor $\mathbf{p}$ acrescido de variáveis de folga
$pbest_i$	Melhor posição do agente $i$ na iteração $k$ nas meta-heurísticas
$P_T$	Potência de transmissão total consumida
$P_c$	Potência do circuito
$\mathcal{P}$	Operador projeção ortogonal



$\tilde{q}^{(k)}(\cdot)$	Função estritamente côncava que minora $f(\cdot)$ no método MaMi
$rand$	Número aleatório com distribuição uniforme no intervalo $[0, 1]$ nas meta-heurísticas
$r_c$	Taxa de chip
$r_i$	Taxa de símbolos do $i$ -ésimo usuário
$r_{i,\min}^{\text{serv}}$	Taxa de símbolos mínima de serviço para o $i$ -ésimo usuário
$R_{ij}$	Distância euclidiana entre dois agentes $i$ e $j$ no método GSA
$\mathbb{R}^K$	Espaço real de dimensão $K$
$\mathcal{R}$	Robustez do algoritmo
$\rho$	Parâmetro de penalidade do ALM
$\rho_k$	Parâmetro de penalidade na $k$ -ésima iteração no ALM
$\sigma^2$	Potência do ruído aditivo Gaussiano branco
$T_b$	Período de bit
$T_c$	Período de chip
$\mathcal{T}$	Número total de realizações do processo
$\tau$	Representa o nível de decréscimo esperado em $V^k$ no ALM
$u_j(\cdot)$	Estado corrente do $j$ -ésimo neurônio no método mH-NN
$\dot{u}_j(\cdot)$	Estado interno do $j$ -ésimo neurônio, a derivada em relação ao tempo de $u_j(\cdot)$ no método mH-NN
$v$	Classe de serviço
$v_j(\cdot)$	Saída do $j$ -ésimo neurônio no método mH-NN
$v_i^k$	Velocidade da partícula $i$ na iteração $k$ nas meta-heurísticas
$V^k$	Vetor que mede a factibilidade e a complementariedade na $k$ -ésima iteração no ALM
$w$	Peso do código
$w_i$	Largura de banda não espalhada do sinal do $i$ -ésimo usuário
$\bar{w}$	Função de ponderação nas meta-heurísticas
$W$	Largura de banda do sistema óptico
$W_{ji}$	Valor do peso sináptico conectando o $j$ -ésimo neurônio ao $i$ -ésimo neurônio no método mH-NN
$\mathbf{W}^{\text{conf}}$	Matriz de pesos associada a $E^{\text{conf}}$ no método mH-NN
$\mathbf{W}^{\text{ot}}$	Matriz de pesos associada a $E^{\text{ot}}$ no método mH-NN
$x_i^k$	Posição corrente da partícula $i$ na iteração $k$ no método mH-NN
$x_j(t)$	Entrada do $j$ -ésimo neurônio no método mH-NN
$\Omega$	Subconjunto de $\mathbb{R}^K$ definido por restrições simples
$\mathbf{z}^{\text{max}}$	Vetor limitante superior no método mH-NN
$\mathbf{z}^{\text{min}}$	Vetor limitante inferior no método mH-NN
$\nabla$	Operador gradiente
$\nabla_v$	Operador gradiente em relação ao vetor $v$
$\nabla^2$	Operador matriz Hessiana

## LISTA DE NOTAÇÕES

$a, \alpha, A$	Letra em itálico representa um escalar
<b>a</b>	Letra minúscula em negrito representa um vetor
<b>A</b>	Letra maiúscula em negrito representa uma matriz
$\{\cdot\}^T$	Operador matriz transposta
$\{\cdot\}^{-1}$	Operador matriz inversa
$ \cdot $	Operador valor absoluto (módulo)
$\ \cdot\ $	Operador norma Euclidiana
$\mathbb{E}(\cdot)$	Operador esperança estatística
$\mathbf{x}^1 \preceq \mathbf{x}^2$	Indica que a solução $\mathbf{x}^2$ domina a solução $\mathbf{x}^1$
$C_1 \subset C_2$	Indica que $C_1$ é um subconjunto de $C_2$
$C_1 \subseteq C_2$	Indica que $C_1$ é um subconjunto de $C_2$ ou o próprio $C_2$
$\max[\cdot]$	Valor máximo assumido pelo argumento
$\min[\cdot]$	Valor mínimo assumido pelo argumento
$\in$	Pertence
$\nabla$	Operador gradiente
$\nabla_v$	Operador gradiente em relação ao vetor $v$
$\nabla^2$	Operador matriz Hessiana

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>20</b>
1.1 JUSTIFICATIVA	23
1.2 OBJETIVOS	24
1.3 CONTRIBUIÇÕES	25
1.4 ORGANIZAÇÃO DO TRABALHO	26
1.5 PUBLICAÇÕES CIENTÍFICAS ASSOCIADAS AO TRABALHO	27
1.5.1 Artigos Publicados em Periódicos	27
1.5.2 Artigo Aceito em Periódico	27
1.6 CONCLUSÕES DO CAPÍTULO	28
<b>2 REDES OCDMA-PON E PROBLEMAS DE ALOCAÇÃO DE RECURSOS</b>	<b>29</b>
2.1 SISTEMA OCDMA-PON	30
2.1.1 Princípios do modelo do sistema OCDMA-PON	35
2.1.2 Códigos OCDMA	35
2.2 ALOCAÇÃO DE RECURSOS EM REDES OCDMA-PON	37
2.2.1 Problema de Controle de Potência Mínima	37
2.2.2 Problema de máxima Eficiência Energética	40
2.2.3 Problema compromisso SE × EE em redes ópticas OCDMA	44
2.3 CONCLUSÕES DO CAPÍTULO	49
<b>3 ESTRATÉGIAS DE SOLUÇÃO DO PROBLEMA DE ALOCAÇÃO DE POTÊNCIA MÍNIMA</b>	<b>50</b>
3.1 SOLUÇÃO ALGÉBRICA DO PROBLEMA DE ALOCAÇÃO DE POTÊNCIA MÍNIMA	50
3.2 MÉTODOS DE OTIMIZAÇÃO ABORDADOS	51
3.2.1 Rede Neural de Hopfield	51
3.2.2 Rede de Hopfield Modificada	55
3.2.3 Programação Quadrática Sequencial	59
3.2.4 Método do Lagrangiano aumentado	62
3.3 IMPLEMENTAÇÃO, FACTIBILIDADE E COMPLEXIDADE DO ALGORITMO	64
3.3.1 Aspectos de Implementação dos algoritmos analisados	64
3.3.2 Critério de Parada e Factibilidade	65
3.3.3 Erro Médio Quadrático Normalizado	65
3.3.4 Robustez Algorítmica	66
3.4 RESULTADOS NUMÉRICOS	66
3.4.1 Otimização da Alocação da Potência (Cenário A)	66
3.4.2 Otimização do Controle de Potência com Diferentes Níveis de QoS (Cenário B)	72
3.4.3 Análise de Complexidade	75
3.4.3.1 Análise de Desempenho Dinâmico	80
3.5 CONCLUSÕES DO CAPÍTULO	85

<b>4</b>	<b>ESTRATÉGIAS PARA A ALOCAÇÃO EFICIENTE DE POTÊNCIA:</b>	
	<b>MAXIMIZAÇÃO DA EFICIÊNCIA ENERGÉTICA</b>	<b>86</b>
4.1	MÉTODOS DE PROGRAMAÇÃO NÃO LINEAR	88
4.1.1	Método Dinkelbach	88
4.1.1.1	Programação Convexa Disciplinada	89
4.1.2	Método de Programação Quadrática Sequencial	90
4.1.3	Método do Lagrangiano aumentado	91
4.1.4	Método de Majoração-Minimização	93
4.2	ASPECTOS DE IMPLEMENTAÇÃO DOS MÉTODOS DE PNL NA SOLUÇÃO DO PROBLEMA EE-OCDMA	95
4.3	RESULTADOS NUMÉRICOS	98
4.3.1	Otimização de EE sem restrição no serviço de taxa mínima $r_{\min}^{\text{serv}}$ (Cenário A)	99
4.3.2	Otimização de EE com restrição no serviço de taxa mínima, $r_{\min}^{\text{serv}}$ (Cenário B)	100
4.4	TEMPO DE EXECUÇÃO EM CENÁRIOS DIFERENTES	106
4.5	CONCLUSÕES DO CAPÍTULO	109
<b>5</b>	<b>ESTRATÉGIAS HÍBRIDAS DE OTIMIZAÇÃO PARA A EFICIÊNCIA ENERGÉTICA EM REDES OCDMA</b>	<b>110</b>
5.1	MÉTODOS DE OTIMIZAÇÃO	112
5.1.1	Método de Lagrangiano aumentado	112
5.1.2	Otimização por enxame de partículas	114
5.1.3	Método de Otimização por busca gravitacional	115
5.1.4	Método de Otimização híbrido PSO-GSA	117
5.1.5	Método BFGS	118
5.2	ASPECTOS DE IMPLEMENTAÇÃO DOS MÉTODOS DE OTIMIZAÇÃO PARA EE-OCDMA	120
5.3	RESULTADOS NUMÉRICOS	121
5.3.1	Otimização de EE com restrição no serviço de taxa mínima ( $r_{\min}^{\text{serv}}$ )	123
5.3.2	Comparação com outros métodos meta-heurísticos	129
5.4	CONCLUSÕES DO CAPÍTULO	132
<b>6</b>	<b>OTIMIZAÇÃO DO COMPROMISSO EFICIÊNCIA ENERGÉTICA E EFICIÊNCIA ESPECTRAL EM REDES OCDMA</b>	<b>133</b>
6.1	RESOLUÇÃO DO PROBLEMA MULTIOBJETIVO DO COMPROMISSO EE × SE	134
6.1.1	Método da Soma Ponderada	134
6.1.2	Método $\epsilon$ -restrito	137
6.1.3	Método do Lagrangeano aumentado	139
6.1.4	Programação Quadrática Sequencial	141
6.2	DETALHES DE IMPLEMENTAÇÃO	142
6.2.1	Erro quadrático médio normalizado	143
6.3	RESULTADOS NUMÉRICOS	144
6.3.1	Compromisso EE-SE sem restrição na taxa mínima de serviço $r_{\min}^{\text{serv}}$ (Cenário A)	145
6.3.2	Compromisso EE-SE com restrição na taxa mínima de serviço, $r_{\min}^{\text{serv}}$ (Cenário B)	149
6.4	CONCLUSÕES DO CAPÍTULO	157
<b>7</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>158</b>
	<b>REFERÊNCIAS</b>	<b>161</b>

## 1 INTRODUÇÃO

O grande número de tecnologias de comunicação e os novos serviços em 5G fazem com que as redes de telecomunicações se transformem em uma complexa estrutura, e isso possibilita às pessoas usarem diversos tipos de sistemas e equipamentos para se comunicarem de forma rápida, eficiente e mais segura.

O avanço das tecnologias é inevitável e evolui de forma cada vez mais rápida. Sendo assim, a implantação de uma infraestrutura de rede, que seja robusta e atenda às novas necessidades de acesso, é imprescindível e se torna cada vez mais um desafio em termos de investimentos, de opções tecnológicas, bem como de políticas regulatórias. O termo “banda larga” expressa um contraste entre as tecnologias, que utilizam a conexão por meio de linhas telefônicas caracterizadas por possuírem um baixo fluxo de recebimento e envio de dados, e as novas redes digitais, que possibilitam o transporte de voz, dados e imagens.

Os conceitos de transmissão de informações por ondas luminosas já eram conhecidos muito antes pelo homem, mas apenas no século XX, com o avanço dos desenvolvimentos tecnológicos necessários é que foram concretizados. Esse desenvolvimento tornou possível o sonho de transportar luz através de um meio físico guiado, chamado atualmente de fibras ópticas (PINHEIRO, 2017).

Em 1953, o pesquisador Narinder Singh Kapany desenvolveu fibras de vidro com revestimento e introduziu o termo “fibra óptica”, e marcou desse modo o surgimento das esperadas condições tecnológicas. Em 1958, com a invenção do laser e sua primeira prática em 1960, foi possível que as pesquisas em comunicações ópticas tivessem um avanço. No entanto, a fibra óptica tornou-se viável para substituir os cabos metálicos em algumas aplicações de comunicação somente na segunda metade da década de 1960.

A década de 1970 marca a descoberta e a utilização posterior das fibras ópticas com baixas perdas; assim, altas taxas de transmissão e velocidades atingindo a ordem de centenas de gigabits por segundos tornaram-se realidade. O Brasil, ainda no final

da década de 1970, começou a dominar a tecnologia de fibra óptica. A Universidade Estadual de Campinas, no interior de São Paulo, foi a primeira instituição a desenvolver a tecnologia e a produzir fibras ópticas, nessa época.

As redes ópticas se tornaram atraentes por substituírem as redes metálicas com muito mais eficiência, disponibilidade e segurança. Tal fato se deve principalmente porque elas são imunes aos ruídos eletromagnéticos, são capazes também de criar condições mais econômicas para implantação e também novas aplicações.

Durante a década de 1980, com o grande desenvolvimento das comunicações e da informática, as aplicações da fibra óptica se desenvolveram na área de telecomunicações, chegando aos setores da indústria, medicina, astronomia, aplicações militares, automação industrial e residencial, entre outros. Nos anos posteriores a tecnologia foi transferida para a estatal Telebras, que a repassou, no final da década, para empresas privadas começarem a produzir a fibra óptica em escala comercial (PINHEIRO, 2017).

Com o avanço e a evolução da fotônica que utiliza luz como meio para transporte de informações digitais, as fibras ópticas surgem como a alternativa mais viável para as redes de banda larga, para substituir os cabos metálicos possibilitando o aumento da capacidade e da confiabilidade de sistemas de comunicação existentes. Tal alternativa é capaz de atender à demanda e de atingir velocidades expressivas, transportando quantidades elevadas de tráfego que chegam a dezenas de gigabits por segundo, de modo a superar a tecnologia por conexão por meio de linhas telefônicas.

Atualmente, as pesquisas em redes ópticas estão voltadas para busca de sistemas com maior eficiência, maiores capacidades de transmissão e maior alcance com menor número de repetidores. Baseado na evolução da técnica de acesso múltiplo por divisão de código (CDMA – *Code Division Multiple Access*) em sistemas sem fio (ABDULLAH et al., 2012), em meados da década de 1980, foi introduzido o acesso múltiplo por divisão de código em domínio óptico (OCDMA – *Optical Code Division Multiple Access*), (ABD et al., 2012), (WU et al., 2006). O OCDMA foi desenvolvido utilizando a técnica de espalhamento espectral, na qual cada usuário é identificado por um código de espalhamento ou endereço exclusivo. Devido ao enorme crescimento do OCDMA, várias configurações OCDMA foram estabelecidas, podendo ser classificadas em sistemas incoerentes e coerentes (KERAF et al., 2016). A tecnologia CDMA aplicada ao meio óptico efetua operações de codificação e decodificação para prover acesso à rede. No caso de OCDMA, todos os usuários ativos compartilham simultaneamente a totalidade da largura de banda enquanto provê uma certa imunidade à interferência de múltiplo acesso devido à características de

(quase-)ortogonalidade dos códigos de espalhamentos.

Os padrões das redes ópticas passivas (PON – *Passive Optical Networks*) estão em constante evolução, desde o início do ano 2000. Critérios como eficiência energética, coexistência com sistemas legados, flexibilidade espectral e resiliência da rede constituem características de sistema ou métricas de desempenho em redes ópticas. A alocação de recursos adequados em redes OCDMA-PON permite maior capacidade e uso racional e eficiente dos recursos disponíveis, principalmente energia e espectro. Por exemplo, a alocação otimizada da potência, bem como a redução no consumo total de potência são problemas de grande interesse tanto para as empresas de telecomunicações quanto para os usuários. Sendo assim, a proposta de novas técnicas e algoritmos capazes de alocar esses recursos de forma simples e otimizada se torna algo atraente.

Este trabalho de Tese propõe analisar diferentes técnicas de programação matemática não-linear, bem como métodos heurísticos bioinspirados e técnicas de escalarização<sup>1</sup> para otimização multiobjetivo (MOO – *Multiobjective Optimization*) para tratar problemas inerentes às redes de comunicação ópticas OCDMA.

Para a análise de eficiência energética em redes OCDMA, quatro métodos de programação matemática não-linear foram analisados, sendo avaliados e comparados em desempenho e complexidade. Os métodos de otimização abordados nesta Tese são Lagrangiano aumentado (ALM – *Augmented Lagrangian method*), programação quadrática sequencial (SQP – *Quadratic Sequential Programming*), abordagem de Majoração para Minimização (MaMi – *Majorization-Minimization*) bem como o método de Dinkelbach (DK – *Dinkelbach's method*).

Completamos o estudo do problema da eficiência energética com a análise da combinação do ALM com métodos heurísticos evolutivos comparados a versões clássicas do ALM. Foram considerados os métodos heurísticos: otimização de enxame de partículas (PSO – *Particle swarm optimization*), e uma hibridização entre o PSO e o algoritmo de busca gravitacional (GSA – *Gravitational Search Algorithm*), denominado PSOGSA, foram implementados. A estrutura do ALM incorpora a função objetivo, as restrições e permite um melhor ajuste ao problema e, por fim, fornece mais informações sobre a solução.

Para o problema de alocação de potência mínima analisamos a aplicabilidade da Rede Neural Artificial (RNA) do tipo de Hopfield modificada para o problema de alocação

---

<sup>1</sup>Denominamos escalarização a transformação de um problema com vários objetivos em outro com apenas um objetivo.

de recursos para o controle de potência ótima em redes OCDMA. Os testes apresentados na Seção 3.4 demonstraram que a Rede de Hopfield modificada se mostrou adequada para o problema de controle de potência.

Foram utilizadas duas técnicas de escalarização para MOO (ALIANO, 2016) para o problema do compromisso entre eficiência energética e eficiência espectral em redes OCDMA, nominalmente o método da Soma Ponderada (WS – *Weighted Sum Method*), e o método do  $\epsilon$ -restrito ( $\epsilon$ -C –  *$\epsilon$ -Constraint Method*). Essas técnicas foram associadas ao método do Lagrangiano aumentado para resolução dos subproblemas gerados e a qualidade da solução no sentido de Pareto foi verificada.

## 1.1 JUSTIFICATIVA

Nas últimas décadas, a infraestrutura das redes de telecomunicações tem passado por um processo de mudanças para uma arquitetura mais plana e integrada composta de três níveis: processamento, transporte e acesso. O aumento da oferta de serviços e aplicações estimula e justifica a implantação de redes ópticas de acesso (MAODE; YONGQING, 2002). Nos anos 1980, as redes ópticas entraram em operação, usadas inicialmente nos *backbones* de telecomunicações. Nos dias atuais, a tecnologia OCDMA tem se mostrado uma abordagem atrativa devido à arquitetura simples de rede, e também por sua capacidade de suportar vários usuários ao mesmo tempo. Além disso a segurança do sistema OCDMA e a capacidade flexível são duas características desejáveis sob certas condições de demanda variável e escalabilidade do sistema óptico.

O uso do CDMA óptico permite um método de acesso múltiplo flexível para tráfego assíncrono com baixa degradação na presença de interferentes, além de que as taxas de erro podem ser satisfeitas com a escolha adequada do código (HADI; PAKRAVAN, 2017a). Desta forma, o OCDMA suporta um modo de transmissão assíncrono completo com baixa latência e sem utilização de equipamentos elétricos muito complexos.

Com a necessidade crescente em disponibilizar uma maior largura de banda por usuário, surgem as tecnologias de nova geração, como redes PON aplicadas às redes de acesso múltiplo, denominadas OCDMA-PON, como também aplicadas às redes de multiplexação por divisão de comprimento de onda (WDM – *Wavelength Division Multiplexing*), WDM-PON. Estas são capazes de oferecer taxas de *downlink* promissoras ao atender à demanda em gigabits, aumentando o número de usuários por fibra. Isto é possível porque esquemas de múltiplo acesso por divisão de código e comprimento de



onda aumentam o desempenho e eficiência espectral no domínio óptico.

O controle de potência é fundamental para se obter maior número de usuários ativos na rede, cada um com a mínima potência necessária para atingir uma certa qualidade de serviço (QoS – *Quality of Service*) e para minimizar a interferência de múltiplo acesso (MAI – *Multiple Access Interference* (DURAND et al., 2015).

O desenvolvimento de algoritmos de alocação de recursos sob demanda com baixa complexidade é um desafio para a nova geração de redes ópticas passivas (NG-PONs) baseadas em OCDMA relacionadas à eficiência energética (ZULAI et al., 2015), (HADI; PAKRAVAN, 2018), (MARQUES et al., 2016). O crescimento do número de PONs com alta taxa de transmissão e o número de unidades de redes ópticas (ONU – *Optical Network Unit*) na maior área de cobertura, têm contribuído para o aumento do consumo de potência (KAZOVSKY et al., 2017). PONs apresentam baixa eficiência energética considerando o comportamento do tráfego. Logo, a eficiência energética é uma grande preocupação nas PONs, quando comparadas com as grandes redes (como redes intercontinentais e trans-continentais), que apresentam alta eficiência energética relacionada à soma das informações transmitidas e ao consumo de potência.

Neste cenário, buscam-se algoritmos relacionados à alocação de recursos visando a obtenção de baixa complexidade computacional, com a finalidade de reduzir a quantidade de potência consumida, otimizando a eficiência global da rede OCDMA, o que justifica o desenvolvimento desta pesquisa.

## 1.2 OBJETIVOS

O objetivo geral desta Tese de doutorado consiste na proposição, análise e caracterização de técnicas de otimização aplicáveis na resolução de problemas de alocação de recursos em redes ópticas OCDMA. O desenvolvimento de algoritmos é realizado avaliando-se os resultados numéricos em redes nas quais o modelo de sistema adotado opera no limite da robustez, sendo possível assim uma investigação sobre a complexidade computacional, bem como vantagens e desvantagens operacionais e de implementação. Dentre as técnicas de otimização adotadas destacamos as técnicas de programação não-linear, meta-heurísticas, redes neurais artificiais além das técnicas de otimização multiobjetivo como alternativas para solução de problemas relacionados à alocação dos recursos.

Os objetivos específicos deste trabalho são:

- Investigar a complexidade dos algoritmos propostos com intuito de obter algoritmos mais versáteis e robustos, quando comparados aos algoritmos apresentados na literatura;
- Validar as novas abordagens de otimização, comparando as soluções obtidas com aquelas encontradas nas abordagens clássicas da literatura, visando obtenção de maior eficiência em relação à precisão e ao custo computacional para problemas de otimização complexos e geralmente não-convexos;
- Explorar redes neurais artificiais considerando requisitos de qualidade de serviço e alocação de potência mínima;
- Propor e analisar técnicas e algoritmos de alocação de recursos baseadas em Programação Matemática considerando requisitos de qualidade de serviço e eficiência energética;
- Propor e explorar técnicas e algoritmos de alocação de recursos baseadas em Algoritmos Heurísticos;
- Propor e avaliar técnicas e algoritmos de otimização multiobjetivo para o problema do compromisso entre eficiência energética e eficiência espectral.

### 1.3 CONTRIBUIÇÕES

A proposta deste trabalho busca contribuir na construção de resultados de pesquisas relevantes para a otimização de alocação de recursos em redes ópticas CDMA. Justificando a necessidade de otimização desses recursos, os seguintes aspectos foram explorados nesta Tese:

- Desempenho de métodos de programação não linear, aplicados aos problemas de alocação de recursos em redes OCDMA;
- Aplicação da rede neural de Hopfield modificada ao problema de alocação de potência mínima em redes OCDMA;
- Viabilidade do uso do método de programação Lagrangiano aumentado combinado com heurísticas evolutivas, aplicados aos problemas de alocação de recursos em redes OCDMA;

- Alternativas para a formulação e resolução do problema de alocação de recursos, relacionando o compromisso entre eficiência energética e eficiência espectral por meio de técnicas de MOO em redes OCDMA.

#### 1.4 ORGANIZAÇÃO DO TRABALHO

Esta Tese de doutorado contém, além do capítulo introdutório, seis capítulos, os quais foram organizados do seguinte modo:

- **Capítulo 2** - Nesse capítulo são apresentados tanto o modelo de sistema OCDMA quanto sua estrutura física e também os modelos matemáticos analisados, tais como controle de potência, eficiência energética e o problema do compromisso entre eficiência energética e eficiência espectral, caracterizando a métrica de eficiência de recurso.
- **Capítulo 3** - Nesse capítulo são analisadas estratégias de resolução do problema de alocação de potência mínima em redes OCDMA apresentado no Capítulo 2. Dentre as estratégias analisadas encontra-se a solução algébrica via método de inversão de matrizes. Na sequência, uma alternativa à resolução do problema é explorada usando-se redes neurais artificiais (RNA) como a rede de Hopfield Modificada. Os resultados numéricos são apresentados para validação das propostas de otimização da potência mínima.
- **Capítulo 4** - Esse capítulo descreve e propõe a resolução do problema de maximização da eficiência energética em redes OCDMA. Aqui são reproduzidos resultados encontrados na literatura usando como estratégia de resolução o algoritmo de Dinkelbach DK-CVX comparada a uma nova estratégia de resolução utilizando técnicas de programação matemática não-linear, tais como programação quadrática sequencial, Lagrangiano aumentado e Majoração-Minoração. Por fim, são analisados os resultados obtidos extraídos de uma sequência de testes numéricos realizados, bem como se desenvolve uma análise comparada envolvendo a complexidade e a robustez dos algoritmos propostos.
- **Capítulo 5** - Neste capítulo, analisa-se a utilização do método de programação não-linear baseado no Lagrangiano aumentado combinado ao algoritmo heurístico bioinspirado híbrido, a saber o PSOGSA. Este é utilizado como estratégia de resolução do problema de maximização da Eficiência Energética apresentado no Capítulo 2. Os

resultados numéricos são coletados a fim de verificar o desempenho e a complexidade por meio de operações em pontos flutuantes.

- **Capítulo 6** - Neste capítulo, são estudadas estratégias de resolução do problema multiobjetivo de eficiência de recursos (RE), o qual relaciona o compromisso entre eficiência energética e eficiência espectral, por meio de métodos de otimização multiobjetivo como  $\epsilon$ -restrito combinado a métodos de programação não linear, bem como o uso das somas ponderadas.
- **Capítulo 7** - Por fim, neste capítulo são apresentadas as principais conclusões e sugestões para continuidade dos estudos.

## 1.5 PUBLICAÇÕES CIENTÍFICAS ASSOCIADAS AO TRABALHO

Os artigos científicos/tecnológicos gerados como resultado do trabalho de investigação desta Tese de doutorado são sintetizados seguir.

### 1.5.1 ARTIGOS PUBLICADOS EM PERIÓDICOS

- 1 PENDEZA MARTINEZ, C. A.; DURAND, F. R.; ABRÃO, T. Energy-efficient QoS-based OCDMA networks aided by nonlinear programming methods. **International Journal of Electronics and Communications**, v. 98, p. 144 - 155, 2019; DOI: <https://doi.org/10.1016/j.aeue.2018.11.007>, ISSN 1434-8411, Available online: 5 November 2018.

URL: <http://www.sciencedirect.com/science/article/pii/S1434841118321253>

- 2 PENDEZA MARTINEZ, C. A.; DURAND, F. R.; MARTINEZ A.L.M; ABRÃO, T., Augmented Lagrangian Combined to Evolutionary Heuristic for Energy Efficiency in OCDMA Networks. **Optical Switching and Networking**, v. 36, p. 100542, 2020. DOI: <https://doi.org/10.1016/j.osn.2019.100542>, ISSN 1573-4277, Available online: 6 November 2019.

URL: <http://www.sciencedirect.com/science/article/pii/S1573427719300347>

### 1.5.2 ARTIGO ACEITO EM PERIÓDICO

- 3 PENDEZA MARTINEZ, C. A.; ABRÃO, T.; DURAND, F. R.; GOEDTEL, A., Hopfield Learning-based and Nonlinear Programming methods for Resource Allocation in OCDMA Networks. **IET Communications**. Aceito em 05 de abril de 2020. DOI:

<https://doi.org/10.1049/iet-com.2019.0908> , Print ISSN 1751-8628, Online ISSN 1751-8636, Available online: 17 April 2020

URL: <https://digital-library.theiet.org/content/journals/10.1049/iet-com.2019.0908>;

4 PENDEZA MARTINEZ, C. A.; ABRÃO, T., Spectral and Energy Efficiency Tradeoff in OCDMA Networks. **Transactions on Emerging Telecommunications Technologies**. Aceito em 19 de julho de 2020. DOI: <https://doi.org/10.1002/ett.4107>

## 1.6 CONCLUSÕES DO CAPÍTULO

Neste capítulo, foram apresentados os conceitos e objetivos que são desenvolvidos nesta Tese, bem como elencadas as justificativas para o desenvolvimento da pesquisa e a organização dos capítulos. Por fim apresentamos as principais produções bibliográficas resultantes desta Tese.

## 2 REDES OCDMA-PON E PROBLEMAS DE ALOCAÇÃO DE RECURSOS

A tecnologia OCDMA é considerada uma importante alternativa para implantação de redes ópticas de acesso (IMTIAZ et al., 2020). Neste capítulo é apresentada uma análise das características de um sistema OCDMA e são definidos os problemas de alocação de recursos a serem analisados neste trabalho.

Em 1989, a Qualcomm propôs o método CDMA para sistemas celulares, que se estabeleceu em 1993. O sucesso da técnica CDMA em comunicações móveis motivou estudos para sua aplicação em redes ópticas, tal como seus benefícios. A escalabilidade e flexibilidade sob a garantia da qualidade de serviço são os principais aspectos explorados nas bandas ópticas disponíveis (HADI; PAKRAVAN, 2017a). Este método, utilizado para a multiplexação assíncrona dos sinais ópticos, eliminou os atrasos inerentes à multiplexação eletrônica e permitiu o aproveitamento de toda a largura de banda disponível nas fibras.

A tecnologia OCDMA atraiu e ainda suscita grande interesse de pesquisa devido ao fato de oferecer grande largura de banda e flexibilidade de acesso de alta velocidade. Ela tem algumas vantagens, tais como transmissão assíncrona com acesso de baixa latência, atribuição dinâmica de largura de banda, capacidade sob demanda, protocolo de acesso simultâneo, controle de rede simplificado, utilização efetiva de largura de banda, maior flexibilidade de qualidade de controle de serviço e segurança de rede aprimorada (ABDULLAH et al., 2012).

No sistema OCDMA, todos os usuários compartilham uma mesma banda óptica (DURAND et al., 2015), porém cada um deles possui assinatura (código óptico) única. Esses usuários transmitem suas informações simultaneamente para seus respectivos receptores, que possuem assinatura óptica correspondente. Na recepção, somente a informação com a assinatura óptica pertinente é valorizada, visto que, ela maximiza a autocorrelação do seu transmissor com o seu receptor, enquanto outras assinaturas ópticas são encaradas como informações indesejadas, por possuírem correlação cruzada maior que zero

(YIN; RICHARDSON, 2009). Na modulação por chaveamento liga-desliga (OOK – *On-off keying*), os bits “1” a serem transmitidos são codificados no formato de assinatura dos usuários. Os dados codificados são enviados a um acoplador estrela que faz o envio da informação para os receptores desejados.

Um sistema OCDMA comporta múltiplos usuários, baseando em duas condições principais: a) número de assinaturas ópticas que pode ser suportado a partir das sequências pseudoaleatórias disponíveis; b) nível de MAI, provocado quando usuários compartilham o mesmo espectro e a função de correlação cruzada das sequências aleatórias associadas resultam diferentes de zero (YIN; RICHARDSON, 2009).

Uma sequência pseudoaleatória pode ser gerada baseada em técnicas de detecção: coerente ou não-coerente. Sistemas coerentes se fundamentam nas propriedades coerentes da luz, que utilizam codificação bipolar no sinal óptico, ou seja, um dado é aplicado geralmente via codificação de fase do sinal óptico. Os sistemas incoerentes utilizam a presença ou ausência de luz incoerente, para representar símbolos (1 e 0), que caracteriza uma codificação unipolar. Com o desenvolvimento de novos dispositivos de codificação e decodificação, os sistemas coerentes se tornaram a tecnologia mais viável para implementação de sistemas OCDMA (RICHARDSON et al., 2013).

A informação codificada do usuário é resultado do produto da informação e o código gerado de sequências pseudoaleatórias. O comprimento da informação é denotado por período de bit  $T_b$ , enquanto o comprimento da informação codificada é denotado por  $T_b = T_c \cdot F$ , sendo  $T_c$  o período de chip e  $F$  o ganho de processamento da informação codificada. O projeto do gerador de sequências pseudoaleatórias tem como objetivo encontrar a menor correlação cruzada, ou seja, reduzir a MAI, que também é afetada pela camada física da OCDMA-PON. A melhor redução da MAI, resulta no maior número de usuários sob demanda, eficiência energética e redução de custos operacionais.

## 2.1 SISTEMA OCDMA-PON

As redes PONs são alternativas promissoras, uma vez que proporcionam largura de banda, QoS e baixo custo operacional, e permitem altas taxas de transmissão e maiores distâncias de transmissão, além de possibilitarem o compartilhamento da fibra entre os diversos usuários (ASAKA, 2015). Adicionalmente, as redes PON superam as redes ópticas ativas devido à ausência de elementos ativos, com menores custos de implantação, operação e manutenção; são hábeis com demanda de alta taxa de dados que garantem a

qualidade de serviço.

O avanço das tecnologias PONs, tais como redes PON de próxima geração (NG-PONs – *Next-Generation Passive Optical Network*) têm acompanhado o crescimento do tráfego de internet e serviços multimídia em banda larga. As NG-PON podem alcançar taxa de dados de 40 Gbps (YIRAN et al., 2012), ou superior, as quais incluem serviços de gerenciamento de banda e facilidade no uso múltiplo de banda larga e transportam informações ao longo da rede sob um controle de QoS. Vários critérios vêm sendo avaliados e discutidos para o avanço das NG-PONs, em exemplo: eficiência energética; coexistência com sistemas legados; flexibilidade espectral; e resiliência (VILELA, 2017). Todos esses critérios e habilidades, em relação às topologias das PONs anteriores, são consolidados pela melhoria e adoção de técnicas de multiplexação superiores, tal como a tecnologia OCDMA (IMTIAZ et al., 2020).

O sistema OCDMA combina as vantagens do CDMA elétrico com a predominância da largura de banda da fibra óptica e equipamentos de processamento de sinais ópticos (DURAND et al., 2015). Aplicar a tecnologia CDMA em redes ópticas consiste em efetuar operações de codificação e decodificação para otimizar a banda disponível. Neste contexto, a tecnologia OCDMA é uma forte candidata para futuras redes ópticas de acesso (LI et al., 2020), (BALDI et al., 2019) mantida a característica fundamental da associação de uma sequência óptica para cada usuário.

Através da técnica de espalhamento espectral (*spread spectrum*), pulsos ultracurtos e com grande largura espectral são produzidos e manipulados, no domínio óptico, sendo que as demandas de serviço podem alcançar alta taxa de transmissão de dados (JABER et al., 2019). Nessas redes todos os usuários compartilham a totalidade da largura de banda de modo aleatório (TARHUNI, 2019). Assim, cada usuário possui um código óptico ortogonal permitindo que seja identificado unicamente pela assinatura, diferenciando-se dos códigos dos demais usuários (SINGH; SINGH, 2017a). Entretanto, devido às limitações construtivas da rede óptica (diferentes atrasos para os nós ópticos), pode não ser possível obter códigos perfeitamente sincronizados e ortogonais no receptor. Assim, geralmente o sistema OCDMA opera sujeito à interferência MAI (SINGH; SINGH, 2017b).

As vantagens da tecnologia OCDMA em conjunto com os aspectos promissores das PONs, configuram a arquitetura de rede óptica OCDMA-PON, como ilustrado na Figura 1 (RICKEN et al., 2015). Na Figura 1, a arquitetura OCDMA-PON é composta por três principais elementos: unidades de rede óptica (ONUs), localizadas próximas às residências/escritórios (usuários) da rede; terminal de linha óptico (OLT – *Optical Line*



*Terminal*), geralmente localizado no escritório central (CO – *Central Office*) (operadora); e de nós remotos (RN – *Remote Node*). As ONUs são interligadas por meio de um ou mais estágios de RN, um elemento passivo localizado entre as ONUs e a OLT. O RN é responsável por conectar todos os links de fibra provenientes das ONUs e ligá-los com OLT através de um único link de fibra. O OLT é responsável por controlar e administrar os códigos ópticos transmitidos para as ONUs e recebido das ONUs. A OLT possui única estrutura multi-porta com codificador/decodificador baseada em AWGN para gerar e reconhecer códigos ópticos simultâneos com um único dispositivo. É empregado para conectar a PON com serviços de voz, vídeo e dados provenientes de redes metropolitanas (MAN – *Metropolitan Area Networks*) e redes de área ampla (WAN – *Wide Area Networks*) (RICKEN et al., 2015), (WONG, 2012).

A tecnologia empregada nos RN são dispositivos passivos, tais como estrela passiva (YIN; RICHARDSON, 2009), que é utilizada para agrupamento/distribuição dos canais de *upstream/downstream*. Na operação de *downstream* que é originada na OLT com destino para as ONUs é empregada a operação de difusão (*broadcast-and-select*), por outro lado, na operação de *upstream* que é originada nas ONUs com destino para a OLT é empregada a operação de OCDMA (WONG, 2012). As ONUs adotam uma grade de Bragg de fibra superestruturada (SSFBG – *Super-Structured Fiber Bragg Grating*) para o conversor de sinal elétrico para óptico (E/O), que possui características tais como, baixa perda de inserção independente do comprimento de código, desempenho de polarização independente e boa conectividade com a fibra óptica (TEH et al., 2002). As ONUs e OLT geram códigos coerentes com modulação por deslocamento de fase (PKS – *Phase-Shift Keying*), com informação por código, incorporada na fase.

No OLT, os sinais recebidos são correlacionados com uma sequência de assinatura específica que permite a decodificação das informações vindas das ONUs. Desta forma, os sinais de dados dos usuários são multiplexados com sinais de controle para serem transmitidos na fibra até o detector das ONUs. Cada usuário então é separado e identificado pela operação de correlação óptica, como pode ser visto na Figura 2.

Considerando os dados provenientes das ONUs para OLTs, conforme Figura 3, no circulador óptico são multiplexados sinais de controle e dados. Em seguida nos OLTs, os sinais são novamente separados em sinais de dados e de controle no decodificador o que permite a recuperação dos dados transmitidos pelo usuário.

As principais características do sistema OCDMA-PON são:

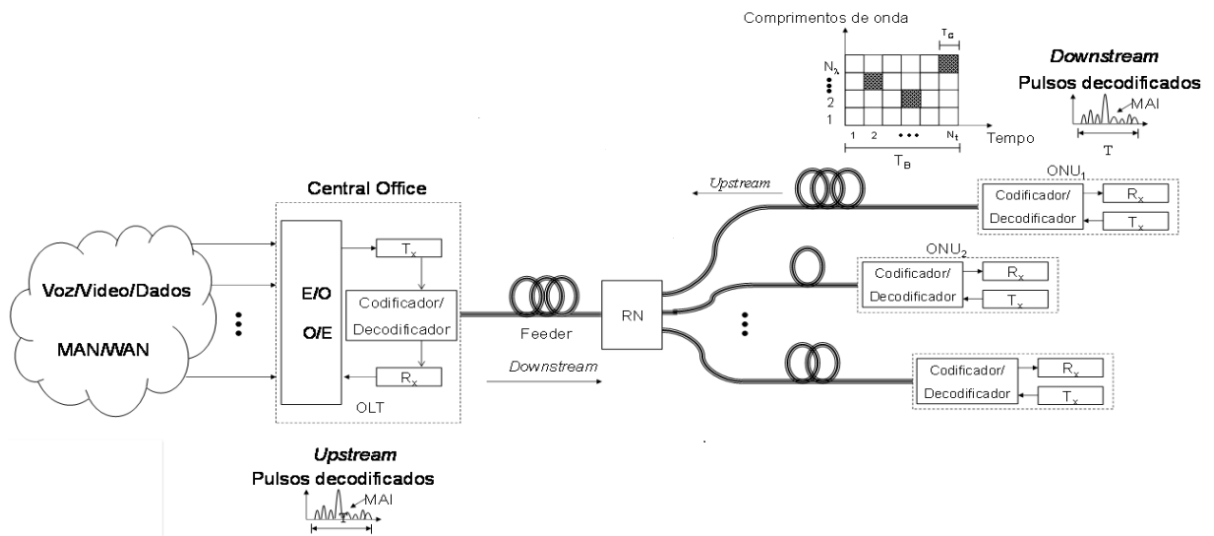


Figura 1: Arquitetura OCDMA-PON.

Fonte: Adaptado de (RICKEN et al., 2015)

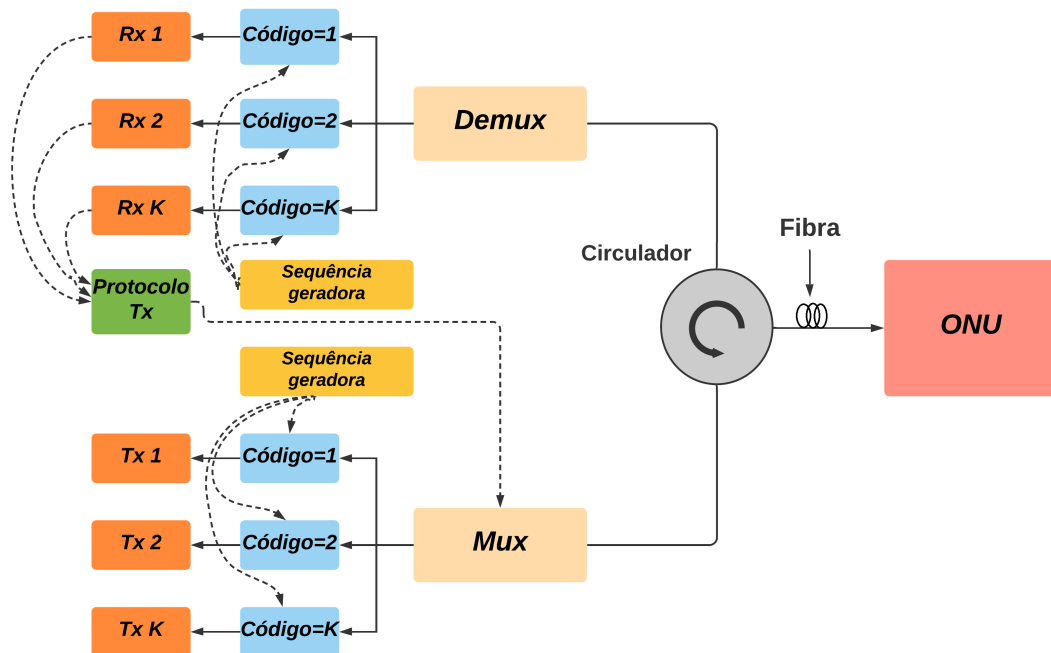
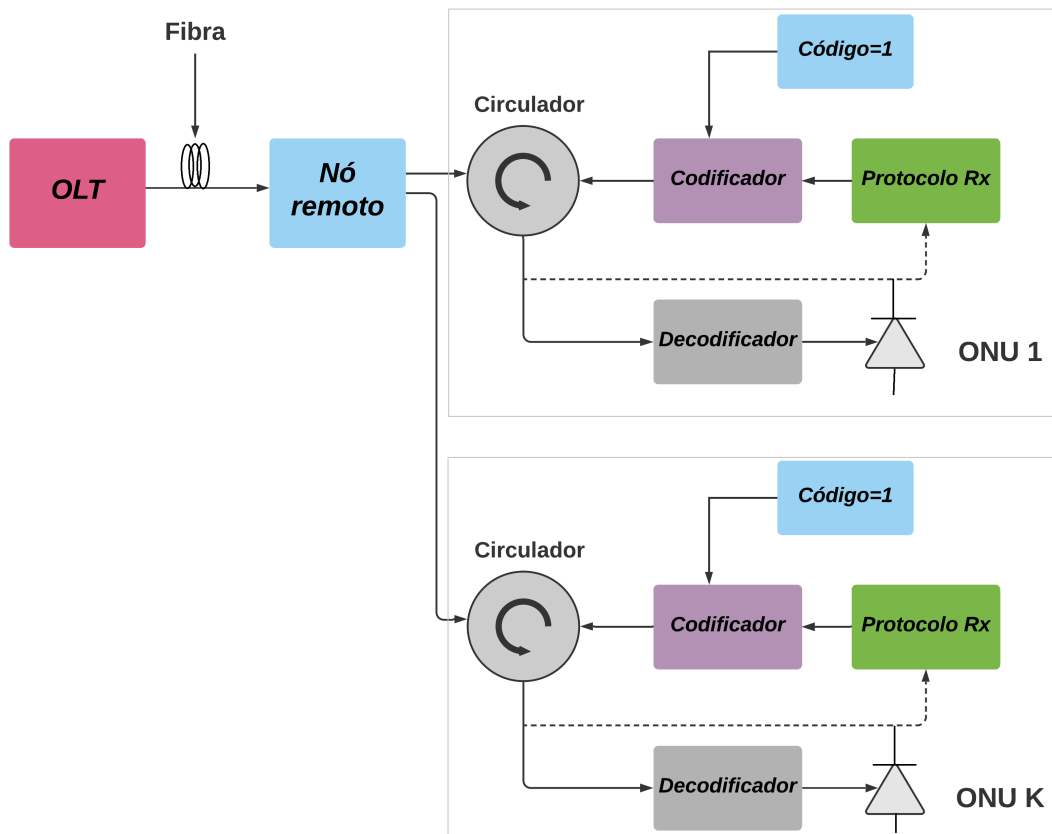


Figura 2: OLT para OCDMA-PON.

Fonte: Autoria própria

- Todos os usuários transmitem simultaneamente, espalhados espectralmente na banda disponível, cada um possuindo um código próprio (sequência única);



**Figura 3: ONU para OCDMA-PON.**

**Fonte: Autoria própria**

- A autocorrelação entre a máscara de seu código com o sinal enviado deve ser maximizada, enquanto a correlação cruzada entre os códigos deve ser minimizada, a fim de extrair o máximo de (quase) ortogonalidade (grau de diferenciação) e cardinalidade (quantidade de códigos disponíveis);
- Codificação no domínio do tempo (manipulando chips temporais), codificação no domínio da frequência (manipulando distintos comprimentos de onda) ou ambos;
- Possui capacidade flexível sob demanda.

O desempenho do sistema OCDMA-PON é basicamente limitado pela interferência de múltiplo acesso, ou interferência multiusuário, o que caracteriza uma limitação do sistema OCDMA-PON. Ou seja, quanto maior o número de usuários ativos na rede, maior a degradação da taxa de erro de bit (BER – *Bit Error Rate*). Outra limitação desta técnica é relacionada à camada física, pois esta tecnologia faz grande uso de componentes optoeletrônicos avançados, com custos ainda elevados.

### 2.1.1 PRINCÍPIOS DO MODELO DO SISTEMA OCDMA-PON

A métrica de QoS pode ser aferida pela BER, que leva em consideração todos os aspectos físicos e multiplexação do sistema OCDMA. A BER está diretamente associada à relação sinal ruído mais interferência (SINR – *Signal to Interference plus Noise Ratio*). Por sua vez, a SINR está associada à relação entre a potências da portadora e a potência do ruído mais interferência (CINR – *Carrier to Interference plus Noise Ratio*):

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

$\gamma_i$  é a SINR do  $i$ -ésimo usuário,  $r_c$  é a taxa de chip,  $r_i$  é a taxa de símbolos do  $i$ -ésimo usuário,  $K$  é o número de usuários no sistema e  $\Gamma_i$  é a CINR do  $i$ -ésimo usuário (GROSS et al., 2011):

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

$p_i$  é a potência de transmissão do  $i$ -ésimo usuário,  $K$  é o número de usuários do sistema,  $G_{ii}$  representa a atenuação do sinal do caminho do código óptico,  $G_{ij}$  representa a atenuação entre o  $j$ -ésimo nó transmissor e  $i$ -ésimo nó receptor e  $\sigma^2$  é a potência do ruído aditivo gaussiano branco (AWGN – *Additive White Gaussian Noise*) à entrada do  $i$ -ésimo receptor. O ruído AWGN é comum aos canais de comunicação sendo caracterizado por uma distribuição estatística Gaussiana de média zero e variância  $\sigma^2$  em uma ampla faixa de frequência.

A matriz de atenuação da fibra  $\mathbf{G}$  que conecta todos os pares transceptores é definida por:

$$\mathbf{G} = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1K} \\ G_{21} & G_{22} & \dots & G_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ G_{K1} & G_{K2} & \dots & G_{KK} \end{bmatrix}. \quad (3)$$

### 2.1.2 CÓDIGOS OCDMA

A técnica OCDMA-PON é uma importante alternativa para implantação das futuras redes ópticas de acesso (IMTIAZ et al., 2020), nas quais cada usuário possui uma assinatura (código óptico) única. Na recepção, apenas o código de interesse apresentará nível aceitável de sinal (autocorrelação) e os demais códigos são interferentes (níveis re-

duzidos de correlação cruzada). Assim, este tipo de rede pode vir a apresentar uma degradação maior do sinal devido, à quantidade de usuários admitidos no sistema.

Existe uma diversidade de técnicas para efetuar codificação e decodificação de dados dos usuários em sistemas OCDMA, sendo que as primeiras a serem utilizadas são chamadas de técnicas de codificação temporal, as quais manipulam somente o domínio do tempo para codificação do bit de informação do usuário. Esses códigos são denominados de códigos de uma dimensão (1D) (JABER et al., 2019). Uma outra dimensão pode ser acrescentada tendo em vista contornar a ineficiência do uso da largura de banda sob altas taxas de codificação. Esta dimensão se refere ao comprimento de onda do sinal óptico, sendo esses códigos denominados códigos de duas dimensões (2D). Os códigos ópticos 2D apresentam melhor desempenho que os códigos 1D e podem suportar quantidade superior de usuários ativos sujeitos a mesma interferência de múltiplo acesso.

O sistema OCDMA pode ser dividido em unipolar não-coerente, que permite somente modulação de intensidade da potência óptica e bipolar coerente, o qual consiste na modulação de amplitude e fase. Os códigos 2D podem ser representados por matrizes  $N_\lambda \times N_T$ , em que  $N_\lambda$  é o número de linhas, referente ao número de comprimentos de onda disponíveis, e  $N_T$  é o número de colunas, referente ao comprimento do código (MARQUES et al., 2016). O comprimento do código é determinado pelo período de bits  $T_b$ , subdividido em pequenas unidades, ou seja, chips, cada um com duração  $T_c = T_b/N_T$ . Em cada código, existem  $w$  pulsos curtos de diferentes comprimentos de onda, sendo  $w$  o peso do código. Um código  $(N_\lambda \times N_T, w, \lambda_a, \lambda_c)$  é uma coleção de matrizes binárias  $N_\lambda \times N_T$ , cada uma com código peso  $w$ ; o parâmetro  $\lambda_a$  é um número inteiro não negativo que representa a restrição na autocorrelação de códigos 2D, enquanto o parâmetro  $\lambda_c$  é um número inteiro não negativo e representa a restrição de correlação cruzada. O projeto e a seleção do código 2D são muito importantes para o bom desempenho do sistema, bem como a obtenção de alta escalabilidade de rede com baixa BER.

A rede OCDMA-PON, utilizada neste trabalho, considera códigos 2-D definidos por códigos primos por saltos de comprimento de onda estendidos (MLEWHPC – *Multiple-length Extended Wavelength-hopping Prime Codes*). Os códigos 2-D MLEWHPC são uma nova família de códigos primos de saltos de comprimento de onda estendidos (EWHPC – *Extended Wavelength-Hopping Prime Codes*), porém de peso constante. Eles suportam uma grande variedade de serviços multimídia, como dados, voz, imagem e vídeo, e acomodam simultaneamente inúmeros tipos de assinantes com taxas de bits e qualidade de serviço (QoS) diferentes. Esses códigos têm propriedades de correlação ideais

(autocorrelação igual a  $N_T$  e correlação cruzada igual a  $\frac{1}{N_T}$ ) as quais podem ser obtidas estendendo-se códigos primos de comprimento único para códigos com distintos comprimentos de onda (múltiplos saltos). Todos os códigos MLEWHPCs resultantes terão as mesmas propriedades de autocorrelação bem como apresentarão correlação cruzada mínima, isto é, no máximo  $\frac{1}{N_T}$  (YIN; RICHARDSON, 2009), (KITAYAMA, 1998), (LIN et al., 2017).

Os códigos 2D bipolares/unipolares e bipolares/bipolares melhoraram substancialmente o desempenho do sistema OCDMA, às custas de maiores requisitos de hardware para o codificador e decodificador, aumentando a complexidade e o custo da implementação (YIN; RICHARDSON, 2009). Aplicações desses dois tipos de códigos de polarização (bipolares/unipolares e bipolares/bipolares) dependem da tecnologia de componentes ópticos e da tecnologia de dispositivos eletrônicos. Tais códigos podem suportar diferentes classes de serviços para diferentes usuários sob demanda. Deste modo, a rede OCDMA pode oferecer a integração de diferentes serviços sob diferentes QoS (AHMED et al., 2020).

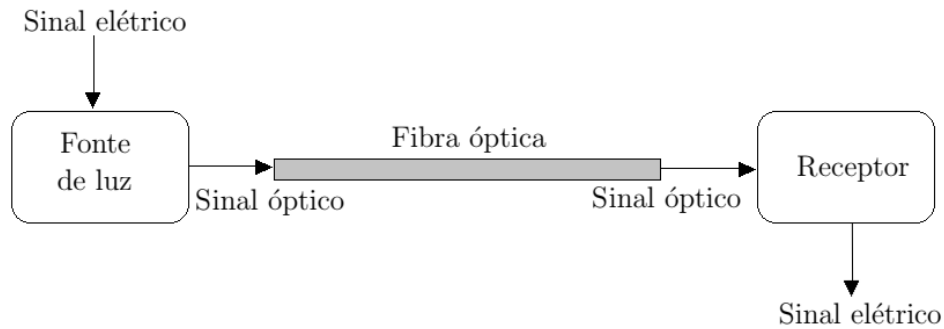
## 2.2 ALOCAÇÃO DE RECURSOS EM REDES OCDMA-PON

Nesta seção serão definidos os problemas de alocação de recursos em redes OCDMA analisados neste trabalho a partir do uso de técnicas de otimização com a finalidade de determinar soluções implementáveis para os mesmos.

### 2.2.1 PROBLEMA DE CONTROLE DE POTÊNCIA MÍNIMA

Um enlace óptico é formado por um circuito eletrônico com uma entrada elétrica que é, então, convertida para uma saída óptica através de um transmissor óptico. A luz do transmissor é acoplada na fibra mediante um conector e assim é transmitida através do cabo óptico, conforme esquema apresentado na Figura 4. No outro extremo, a luz é acoplada através de um receptor e, por meio de um detector, efetua a conversão do sinal óptico em sinal elétrico novamente.

De maneira similar ao meio metálico ou transmissão via rádio, o desempenho de um enlace com fibras ópticas pode ser determinado pela comparação do sinal elétrico obtido no receptor com relação ao sinal da entrada do transmissor. A capacidade de um sistema de transmissão por fibras ópticas depende da potência óptica e da qualidade dos componentes no receptor.



**Figura 4: Esquema da transmissão óptica.**

**Fonte: Autoria própria**

A BER é uma função da potência óptica que chega ao receptor. Baixa ou excessiva, a potência recebida pode causar taxa de erro de bits inaceitáveis. A potência de recepção depende de dois fatores básicos: primeiro, quanto de potência é lançada na fibra pelo transmissor e, segundo, quanto de potência é perdida no meio óptico que conecta o transmissor ao receptor.

Motivados pelo controle de potência realizado em sistemas sem fio, o qual mostrou ser eficiente (YASHIMA; KOBAYASHI, 2003), o procedimento de controle de potência foi sugerido para as redes OCDMA, com o propósito de que as potências recebidas de todos os usuários se tornem iguais, resultando em um considerável ganho de capacidade devido à minimização do efeito da MAI total. Com o aumento da demanda de vários níveis de QoS e com nós espalhados geograficamente, o controle de potência torna-se um ponto crítico em redes OCDMA (SANTOS, 2015). Adotar sistemas com vários níveis de QoS torna as redes ópticas muito mais eficientes devido à otimização dos recursos disponíveis (TARHUNI et al., 2006).

A otimização da SINR, para que os níveis de potência não sejam insuficientes, é baseada na definição da limitação da potência mínima (também chamada de nível de sensibilidade), assegurando que o sinal óptico seja detectado por todos os dispositivos. No outro extremo, deve-se limitar a potência máxima como consequência da necessidade de minimização dos efeitos físicos não lineares da fibra; desta forma, a potência total de um enlace óptico deve ser limitada a um valor específico máximo. Sendo assim, o controle de potência em redes OCDMA aparece como um problema de otimização com limitantes de alocação de potência bem definidos. A fim de se atingir uma QoS específica associada a uma taxa de BER máxima tolerada pelo  $i$ -ésimo nó óptico, a CINR necessária, no decodificador do receptor da rede óptica, pode ser definida como em (2).

O objetivo do problema de alocação de potência mínima consiste em encontrar a mínima potência de transmissão para cada usuário do sistema satisfazendo, ao mesmo tempo, todos os requisitos de QoS, enquanto oferece a vantagem de propiciar uma solução de melhoria da eficiência energética do sistema OCDMA como um todo. Tais requisitos de QoS estão resumidos basicamente à mínima taxa de transmissão de informação e à máxima BER tolerável. Assim, podem ser resumidos em SINR utilizando-a como restrição para a garantia de QoS.

O problema de controle de potência pode ser matematicamente descrito como:

$$\begin{aligned} \min_{\mathbf{p}} \quad & J_1(\mathbf{p}) = \mathbf{1}^T \mathbf{p} = \sum_{i=1}^K p_i \\ \text{s. t.} \quad & \Gamma_i = \frac{G_{ii} p_i}{\sum_{j=1, j \neq i}^K G_{ij} p_j + \sigma_i^2} \geq \Gamma_i^* \\ & p_{\min} \leq p_i \leq p_{\max}, \quad \forall i = 1, \dots, K, \end{aligned} \quad (4)$$

$J_1$  é a função custo para o controle de potência,  $\mathbf{1}^T = [1, \dots, 1]$ ;  $\Gamma_i$  é a CINR do  $i$ -ésimo usuário;  $\Gamma_i^*$  é a CINR alvo mínima do  $i$ -ésimo usuário para atingir o nível de QoS desejado;  $p_{\min}$  é a potência óptica mínima de transmissão e  $p_{\max}$  é a potência óptica máxima de transmissão.

O problema de controle de potência em redes OCDMA pode ser classificado como um problema de programação não linear e não convexo devido à restrição da CINR imposta.

O Capítulo 3 deste trabalho propõe o uso da rede neural de Hopfield modificada, *Modified Hopfield neural network* (mH-NN), especialmente construída para resolver o problema de alocação mínima de potência em redes OCDMA com garantia de QoS. Por fim, uma comparação entre a rede mH-NN e métodos de otimização clássicos, como programação quadrática sequencial e o método Lagrangiano aumentado é realizada. Estes métodos são aplicados na resolução do problema de alocação mínima de potência, levando-se em consideração a velocidade de convergência, factibilidade, complexidade na otimização de redes OCDMA realísticas.

Além disso, no Capítulo 3 é demonstrado que as metodologias estudadas são adequadas à resolução do problema de alocação mínima de potência em redes ópticas OCDMA operando em diferentes cenários do sistema, com diferentes taxas mínimas de serviço. Destacamos que a rede Hopfield modificada proposta provou ser uma boa alternativa para resolver o problema em redes OCDMA, quando comparada aos métodos



clássicos de programação, devido ao seu baixo custo computacional, enquanto sua simplicidade de implementação não requer treinamento prévio. Mais detalhes serão apresentados no Capítulo 3.

### 2.2.2 PROBLEMA DE MÁXIMA EFICIÊNCIA ENERGÉTICA

Trabalhos recentes destacam a importância em se considerar fatores como consumo de energia por bit transmitido em projetos de comunicações ópticas. Tais fatores estão associados à infraestrutura de transmissão dessas redes de transmissão, incluindo transmissores, receptores, fibras e amplificadores (TSENG et al., 2016). Outro fator destacado se refere à infraestrutura de rede, tais como computadores e roteadores. Pesquisas vêm demonstrando que o consumo de potência da infraestrutura de comutação é maior que o consumo de potência da infraestrutura de transporte (TUCKER, 2011). No atual cenário de desenvolvimento e expansão dessa tecnologia de transmissão, é evidente a necessidade de melhoria da eficiência energética e a otimização do desempenho da rede a fim de reduzir a quantidade de comutações e sobreposições.

Neste contexto, um paradigma interessante para a alocação de recursos é a eficiência energética, que visa maximizar a quantidade de informação transmitida por unidade de energia (medida em bits por Joule) (REVIRIEGO et al., 2015), (MIAO et al., 2010). Os desenvolvimentos recentes envolvendo a alocação de recursos baseados na eficiência energética (EE – *Energy Efficiency*) procuram formular o problema no contexto de redes de acesso múltiplo, por exemplo, em Acesso Múltiplo por Divisão de Frequências Ortogonais (OFDMA – *Orthogonal Frequency Division Multiple Access*) e OCDMA (HADI; PAKRAVAN, 2017b), (SHOREH et al., 2015). A análise de eficiência energética em sistemas OCDMA deve considerar a otimização conjunta de sequências de espalhamento e topologias de receptor, a fim de reduzir os efeitos da interferência de acesso múltiplo. Enquanto em sistemas OFDMA, a otimização conjunta deve levar em conta a alocação de subcanais e potência de tal modo a maximizar a EE do sistema óptico.

O problema de otimização de EE tem como objetivo determinar a potência de transmissão correspondente a cada usuário  $i = 1, 2, \dots, K_v$  ( $K_v$  denota o número de usuários da classe  $v$ ) da classe de serviço  $v = 1, 2, \dots, \mathcal{C}$ , correspondendo a diferentes classes de QoS e taxa de bits definidas por multimídia (KWONG; YANG, 2002) de tal sorte a maximizar a EE do sistema OCDMA. Cada classe  $\text{CLASSE}_v$  deve satisfazer os requisitos mínimos de QoS correspondentes à SINR específica. Portanto, o número total de usuários ativos na rede OCDMA é definido por  $K = \sum K_v$ .

Em geral, assume-se que a taxa de símbolos para o  $i$ -ésimo usuário é uma função da SINR  $\gamma_i$  atingível que, da perspectiva da capacidade, pode ser diretamente associada à eficiência espectral usando a equação de capacidade de Shannon (SCHAIBLE, 1976):

$$r_i = w_i \log_2(1 + \gamma_i) \quad [\text{bit/s}] \quad (5)$$

$w_i$  é a largura de banda não espalhada do sinal do  $i$ -ésimo usuário dada por  $w_i = \frac{W}{F_i}$ , com  $W \approx r_c$  sendo largura de banda do sistema óptico com espalhamento espectral, considerada igual para todos os usuários,  $r_c$  é a taxa de chip e  $F_i$  o ganho de processamento do  $i$ -ésimo usuário. A capacidade definida na equação anterior é apenas um limite teórico (máxima taxa alcançável considerando canal AWGN equivalente de SINR  $\gamma_i$ ); logo é necessário inserir um fator de ajuste (*gap*) que possa simular as limitações e imperfeições presentes nos sistemas de comunicação reais, como os efeitos de modulação (SHANNON, 1948).

Uma maneira de expressar este *gap* consiste em agregar um fator  $\theta_i$  no termo de SINR, logo temos:

$$r_i = w_i \log_2(1 + \theta_i \gamma_i), \quad \forall i \quad [\text{bit/s}] \quad (6)$$

$\theta_i \in (0, 1)$  mapeia o limite teórico SINR na equação de Shannon em uma informação real alcançável  $r_i$ .

Em (FOSCHINI; SALZ, 1983) a BER para um canal AWGN com modulação de amplitude em quadratura, detecção de fase coerente ideal e SINR  $\gamma_i$  é limitado por:

$$\text{BER}_i \leq 2 \exp \left[ \frac{-1, 5\gamma_i}{(M-1)} \right] \quad (7)$$

para ordem de modulação  $M \geq 4$  e  $0 \leq \gamma_i \leq 30\text{dB}$ , a limitação pode ser ainda mais restrita como segue:

$$\text{BER}_i \leq 0, 2 \exp \left[ \frac{-1, 5\gamma_i}{(M-1)} \right]. \quad (8)$$

Para a potência de transmissão  $p_i(\gamma_i)$  em relação a  $\gamma_i$ , sujeita à potência média  $\bar{p}$  constante, o BER recebido é então

$$\text{BER}_i \leq 0, 2 \exp \left[ \frac{-1, 5\gamma_i p_i(\gamma_i)}{M-1 \bar{p}} \right]. \quad (9)$$

Como (GOLDSMITH, 2002), ajustamos  $M$  e  $p_i(\gamma_i)$  para atingir o BER alvo. Reorganizando, (9) obtém-se o seguinte tamanho máximo da constelação para um determinado BER:

$$M(\gamma_i) = 1 + \frac{1, 5\gamma_i}{-\log(5\text{BER}_i)} \frac{p_i(\gamma_i)}{\bar{p}} = 1 + \theta_i \gamma_i \frac{p_i(\gamma_i)}{\bar{p}}. \quad (10)$$

Consequentemente o fator  $\theta_i$  é definido como:

$$\theta_i = -\frac{1,5}{\log(5\text{BER}_i)} < 1 \quad (11)$$

$\text{BER}_i$  é a máxima taxa de erro de bit tolerável para o  $i$ -ésimo serviço do usuário. A modelagem detalhada de (11) pode ser encontrada em (GOLDSMITH, 2002).

O modelo de consumo de potência total adotado aqui é baseado no modelo proposto em (HEDDEGHEM et al., 2012) onde a potência total consumida  $P_T$  é dada por:

$$P_T = \iota \sum_i^K p_i + P_c. \quad (12)$$

O parâmetro  $\iota$  está relacionado à eficiência de energia do *transponder*,  $p_i$  é a potência transmitida para o  $i$ -ésimo usuário e a potência de circuitaria  $P_c$  é um importante fator a ser considerado no problema de EE.

Além disso, o problema de EE ( $\eta_{EE}$ ) para redes OCDMA leva em consideração a taxa de símbolos total  $S$  dada por  $S = \sum_i^K r_i$ . Finalmente, o problema de EE, como em (MARQUES et al., 2016), consiste em encontrar a potência de transmissão apropriada para cada usuário pertencente às diferentes classes com diferentes requisitos mínimos de QoS, que podem ser mapeados em SINR,

$$\max_{\mathbf{p}} J_2(\mathbf{p}) = \eta_{EE} = \frac{\sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i)}{\iota \sum_i^K p_i + P_c} \quad \left[ \frac{\text{bit}}{\text{Joule}} \right]$$

$$(C.1) \quad p_{\min} \leq p_i \leq p_{\max} \quad (13)$$

$$(C.2) \quad \gamma_i \geq \gamma_i^*, \forall i$$

$$(C.3) \quad r_i \geq r_{i,\min}^{\text{serv}}$$

A SINR para o  $i$ -ésimo usuário é dada por

$$\gamma_i = \frac{F_i p_i G_{ii}}{\sum_{j \neq i}^K p_j G_{ij} + \sigma^2}, \quad (14)$$

$J_2$  é a eficiência energética;  $r_{i,\min}^{\text{serv}}$  é a taxa de símbolos mínima de serviço para  $i$ -ésimo usuário;  $\gamma_i^*$  é a SINR alvo;  $\sum_{i=1}^K p_i \leq K p_{\max}$ , sendo  $p_{\max}$  a potência máxima de transmissão disponível em cada nó; o ganho de processamento  $F_i > 1$  é igual ao comprimento do código CDMA óptico,  $F_i = T_b/T_c$  que é a relação entre a banda do sinal espalhado pela

banda de informação do sinal;  $\sigma^2$  é o ruído do receptor;  $w_i = r_c/F_i$  é a largura de banda do sinal de informação original (não-espalhado) referente ao  $i$ -ésimo usuário, enquanto a largura de banda disponível para o  $i$ -ésimo usuário de OCDMA é dada pela taxa de chip  $r_c = T_c^{-1}$ ,  $r_i = T_b^{-1}$  é a taxa de símbolos atingível para o usuário  $i$ . Assumindo uma aproximação Gaussiana para o canal quando um grande número de usuários estão ativos (YANG; KWONG, 1995), a probabilidade de erro de bit para o  $i$ -ésimo usuário pode ser aproximada por:

$$P_b(i) = \frac{1}{2} \operatorname{erfc}(\sqrt{\gamma_i}/2), \quad (15)$$

$\operatorname{erfc}(\cdot)$  é a função de erro complementar (TARHUNI et al., 2006).

Sem perda de generalidade, neste trabalho, considera-se que os efeitos não lineares não devem afetar seriamente o desempenho do sistema, devido ao fato de enlaces de fibra serem admitidos curtos, combinados a baixas potências ópticas. Além disso, podem ser consideradas as técnicas de supressão de efeitos não lineares, incluindo a implantação de pré-amplificador baseado em amplificador de fibra dopada com érbio (EDFA – *Erbium Doped Fibre Amplifier*) que mitiga o aparecimento de efeitos não lineares (INATY et al., 2012). Ademais, os efeitos lineares e não lineares podem ser incluídos como penalidade de potência em (14).

A função objetivo  $J_2(\mathbf{p})$  em (13) determina o nível de potência  $p_i$  com o qual se transmite mais informação por unidade de energia. A restrição (C.1) indica qual potência  $p_i$  não pode exceder à potência máxima de transmissão disponível para o  $i$ -ésimo usuário, enquanto o vetor de alocação de potência correspondente é dado por:

$$\mathbf{p} \in \wp = \{\mathbf{p} \in \mathbb{R}^K \mid p_{\min} \leq p_i \leq p_{\max}\}. \quad (16)$$

A restrição (C.2) garante um QoS mínimo para o  $i$ -ésimo usuário. Além disso, a restrição (C.3) pode ser satisfeita em (C.2), a taxa de símbolos atingível para o  $i$ -ésimo usuário deve ser igual ou maior que a taxa mínima de informação requerida para garantir a QoS do  $i$ -ésimo usuário. Assim, a função de eficiência energética total do sistema, descrita por (13) pode ser maximizada encontrando o vetor de potência capaz de fazer o sistema operar no melhor (pode ser o máximo) ponto de EE, satisfazendo, simultaneamente, as restrições (C.1)-(C.3).

Vale a pena notar que o ponto de máxima EE não corresponde necessariamente ao

ponto de máxima eficiência espectral (SE – *Spectral Efficiency*) especialmente nos casos em que há energia de transmissão suficiente disponível no transmissor. Assim, o valor máximo de EE deve ocorrer com potência inferior à potência máxima disponível. Por outro lado, devido às características da eficiência espectral, seu valor máximo normalmente ocorre com potências superiores a estas.

No Capítulo 4 deste trabalho, uma análise sistemática sobre a eficiência energética nas redes OCDMA foi realizada com o objetivo de propor e comparar quatro métodos analíticos de otimização para o problema EE-OCDMA, sob o ponto de vista da convergência, factibilidade, complexidade e otimização. Quatro métodos de otimização eficientes e promissores, baseados em programação não linear, adequados para maximizar a eficiência energética em sistemas OCDMA, denominados Algoritmos DK-ALM, ALM-EE, SQP-EE e MaMi-EE, foram propostos e extensivamente analisados.

Motivados pelos bons resultados apresentados pelos métodos analíticos para o problema EE-OCDMA, com relação ao desempenho e complexidade, no Capítulo 5 propõe-se a combinação do ALM com métodos heurísticos evolutivos, bem como métodos de otimização quase-Newton aplicados ao problema EE em redes OCDMA. O método PSO e um híbrido entre o PSO e o método GSA, chamado PSOGSA foram implementados para resolução do problema EE. A estrutura do ALM substitui a função *fitness* e permite um melhor ajuste ao problema, fornecendo mais informações sobre a solução. Os resultados numéricos demonstram a robustez e a baixa complexidade do método de otimização híbrido ALM-PSO. Esta estratégia baseada no método Lagrangiano aumentado é capaz de se adaptar mais facilmente às especificidades do problema EE-OCDMA. Já o ALM, associado ao PSOGSA, atinge robustez, porém com alto custo computacional. Por sua vez, o ALM combinado ao método quase-Newton definido por Broyden-Fletcher-Goldfarb-Shanno (BFGS) apresenta convergência para um número restrito de cenários, não tendo um desempenho adequado para redes ópticas com grande número de usuários. Mais detalhes são discutidos no Capítulo 5.

### 2.2.3 PROBLEMA COMPROMISSO SE $\times$ EE EM REDES ÓPTICAS OCDMA

Em *Green Communications*, dentre os temas de interesse de pesquisa, está a análise do compromisso entre a eficiência energética e outras métricas já bem estabelecidas na análise de desempenho de sistemas de comunicação, como, por exemplo SE. O consumo de energia sempre foi uma consideração importante no projeto do sistema de comunicações. Autores como (CHEN et al., 2011b) buscam relacionar essas duas métricas de

forma a obter o melhor compromisso EE-SE. Dentro deste t3pico, uma das quest3es mais importantes se d3a pela caracteriza33o do compromisso EE-SE em ambientes multiusu3rio, tais como os sistemas de m3ltiplo acesso OFDMA, CDMA e OCDMA.

Uma medida importante do desempenho de um sistema de comunica33o 3ptica 3 a efici3ncia espectral  $\eta_{SE}$  que especifica a taxa de dados transferidos por largura de banda 3ptica associada a uma taxa de erro de bit fixa,

$$\eta_{SE} = \frac{\sum_{i=1}^K r_i}{W} \quad \left[ \frac{\text{bits}}{\text{s.Hz}} \right] \quad (17)$$

$K$  3 o n3mero de usu3rios simult3neos,  $r_i$  a taxa de bits e  $W \simeq r_c$  3 a largura de banda 3ptica ocupada pelo sistema.

Devido ao recurso limitado de largura de banda, os sistemas de maior desempenho geralmente s3o aqueles que atingem a maior efici3ncia espectral em uma determinada taxa de erros de bits. Definimos  $\eta_{SE}$  como o n3mero total (m3dio) de bits por segundo entregues livres de erro por unidade de largura de banda, da seguinte maneira:

$$\eta_{SE} = \frac{1}{r_c} \sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i) \quad \left[ \frac{\text{bits}}{\text{s.Hz}} \right], \quad (18)$$

fornecendo a habilidade do sistema de receber informa33es livre de erros por largura de banda dispon3vel do sistema. A efici3ncia espectral 3 uma medida fundamental de desempenho de um sistema de comunica33o. Segundo (TANG et al., 2019) os recursos de espectro dispon3veis est3o longe de serem suficientes para apoiar os sistemas de comunica33o com a crescente demanda para alta taxa de dados.

Em princ3pio, a largura de banda 3 abundante no dom3nio 3ptico. Embora a principal motiva33o para usar o OCDMA n3o seja sua efici3ncia na utiliza33o da largura de banda, a efici3ncia espectral pode, no entanto, ser uma de v3rias medidas importantes consideradas no desempenho do sistema. Em uma rede OCDMA, a efici3ncia espectral afeta a taxa de informa33o por usu3rio, o n3mero de usu3rios permitido na rede e, correspondentemente, o custo por usu3rio ativo no sistema.

De maneira similar ao problema EE, otimizar o problema SE tamb3m apresenta limita33es e desafios. Ao se utilizar o m3ximo de pot3ncia poss3vel para maximizar  $\eta_{SE}$ , reduz-se drasticamente a  $\eta_{EE}$ . A efici3ncia espectral e a efici3ncia energ3tica s3o duas m3tricas importantes na melhoria da taxa de transfer3ncia em sistemas de comunica33o 3ptica com menor custo de energia por bit transferido. No entanto, tais m3tricas geral-

mente são conflitantes (MESHKATI et al., 2007), (MIAO et al., 2010), isto é, o aumento de um parâmetro leva à redução do outro e vice-versa (UDALCOVS et al., 2017).

A eficiência espectral realizável é menor que a eficiência espectral máxima, logo a eficiência espectral de um sistema OCDMA prático pode se aproximar da eficiência espectral máxima usando codificação com correção de erros e modulação multidimensional. Como o número de códigos é geralmente maior que o número de usuários para sistemas OCDMA, geralmente há um conjunto de códigos não utilizados.

Em geral, os problemas mais comuns em relação à alocação de recursos se resumem a maximizar a vazão do sistema ou então minimizar o uso dos escassos recursos como energia e espectro disponíveis garantindo os requisitos mínimos de QoS. A capacidade energética não acompanha o crescimento das necessidades de QoS e, simultaneamente, demandas crescentes de taxas de informação, além de questões ambientais, as quais exigem o uso racional dos escassos recursos, principalmente energia. Busca-se então balancear a vazão do sistema, bem como outros requisitos de QoS, e a potência consumida para atendê-los. Esta medida, conhecida como eficiência energética, pode ser obtida com a relação entre a vazão líquida do sistema (em bits/segundo) e potência total consumida (em Watts) (GOODMAN; MANDAYAN, 2000).

Com a alocação de recursos baseada na eficiência energética é possível determinar, simultaneamente, o nível de potência de todos os usuários (vetor  $\mathbf{p}$ ) com o qual se transmite mais informação por unidade de energia. Porém, este processo não leva em consideração o critério de taxa mínima para o  $i$ -ésimo usuário suficiente para garantir um dos requisitos mínimos de QoS em OCDMA estabelecido pela relação:

$$\gamma_{i,min} = \frac{2^{\frac{r_i}{w_i}} - 1}{\theta_i}. \quad (19)$$

Dado que este critério é de fundamental importância na manutenção dos requisitos de QoS, é necessário avaliar o compromisso entre EE-SE, de maneira que o sistema OCDMA possa equilibrar estas duas importantes métricas.

Um novo paradigma para o compromisso EE-SE nomeado eficiência de recursos (RE – *Resource Efficiency*) é capaz de explorar o *tradeoff* EE-SE, equilibrando o consumo de potência e largura de banda ocupada. Portanto, deve-se obter um equilíbrio simultâneo entre EE e SE. Como apresentado por (TANG et al., 2019), a métrica RE é capaz de explorar o compromisso entre EE e SE, com a ponderação entre ambas as

métricas controladas por  $\beta$ , definida por:

$$\eta_{RE} = \eta_{EE} + \beta \eta_{SE} \quad \left[ \frac{\text{bit}}{\text{Joule}} \right]. \quad (20)$$

O termo  $\beta$  é um fator de ponderação para controlar o equilíbrio de EE e SE. A métrica (20) é capaz de explorar o compromisso entre EE e SE, equilibrando à potência consumida e largura de banda ocupada. Para que (20) seja fisicamente consistente, a unidade de  $\beta$  deve ser  $[1/\text{J}]$ , uma vez que a unidade de EE é  $[\text{bit}/\text{J}]$ , enquanto a unidade de SE é  $[\text{bit}/\text{s.Hz}]$ .

Segundo (ZUO et al., 2018), objetiva-se maximizar ambas as métricas SE e EE através do número de usuários e alocação de potência entre eles. A rede, por sua vez, possui diferentes demandas de comunicação em diferentes cenários. Atualmente, é mais importante aumentar o SE nos horários de pico, mas, por outro lado, fora do horário de pico torna-se mais importante priorizar a EE. Conseqüentemente, é fundamental descrever o problema de eficiência de recursos RE como de natureza multiobjetivo. O problema de otimização relacionado à métrica RE é um problema de otimização multiobjetivo. De modo geral, podemos descrever matematicamente um problema de otimização restrito multiobjetivo, a partir de quatro definições (ALIANO, 2016):

**Definição 1** *Um MOO tem um número  $r > 1$  de funções-objetivos que devem ser minimizadas, sujeito a um conjunto viável  $\mathcal{X} \subseteq \mathbb{R}^n$ ,  $\mathcal{X} \neq \emptyset$ . A forma geral de um MOO é:*

$$\begin{aligned} \max \quad & \mathbf{z} = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_r(\mathbf{x})) \\ \text{s. t.} \quad & \mathbf{x} \in \mathcal{X} = \{\mathbf{x} \in \mathbb{R}^n : g_j(\mathbf{x}) \leq 0, j = 1, 2, \dots, l\}. \end{aligned} \quad (21)$$

- $\mathbf{x} = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^n$ : vetor das variáveis decisórias;
- $z_k = f_k(\mathbf{x})$ :  $k$ -ésima função-objetivo a ser minimizada,  $k = 1, \dots, r$ ;
- $\emptyset \neq \mathcal{X} \subseteq \mathbb{R}^n$ : espaço de decisão ou factível, gerado pelas  $l$  restrições  $g_j(x) \leq 0$ .

**Definição 2** *Uma solução  $\mathbf{x}^1$  domina uma outra solução  $\mathbf{x}^2$ , sendo  $\mathbf{x}^1, \mathbf{x}^2 \in \mathcal{X}$ , se as condições a seguir são satisfeitas:*

1. A solução  $\mathbf{x}^1$  é melhor ou igual que a solução  $\mathbf{x}^2$  em todos os objetivos, isto é, para todo  $k \in \{1, \dots, r\}$  tem-se  $f_k(\mathbf{x}^1) \geq f_k(\mathbf{x}^2)$ ,  $k = 1, \dots, r$ ;
2. A solução  $\mathbf{x}^1$  é estritamente melhor que a solução  $\mathbf{x}^2$ , se em pelo menos uma componente  $\bar{k} \in \{1, \dots, r\}$ , tem-se,  $f_{\bar{k}}(\mathbf{x}^1) > f_{\bar{k}}(\mathbf{x}^2)$ .



A dominância da solução  $\mathbf{x}^1$  em relação a solução  $\mathbf{x}^2$  será representada pela seguinte notação:  $\mathbf{x}^1 \preceq \mathbf{x}^2$ .

**Definição 3** Uma solução  $\mathbf{x}^* \in \mathcal{X}$  é chamada eficiente ou ótima no sentido de Pareto, se não existe uma outra solução  $x \in \mathcal{X}$ , de maneira que  $\mathbf{x} \preceq \mathbf{x}^*$ .

**Definição 4** Uma solução  $\hat{x}$  é fracamente eficiente, se não existe uma outra solução  $x \in \mathcal{X}$ , de modo que  $f_k(\mathbf{x}) > f_k(\hat{\mathbf{x}})$  para todo  $k = 1, \dots, r$ .

Segundo (ALIANO, 2016), os métodos clássicos de MOO transformam o problema multi-objetivo em vários subproblemas escalares, que sob certas condições, geram uma solução eficiente. Porém, as técnicas de MOO podem ser custosas computacionalmente, pois dependem fortemente do desempenho dos métodos que resolvem cada subproblema. Vale ressaltar que, para um número grande de subproblemas, estes métodos podem gerar apenas uma quantidade pequena de soluções eficientes distintas, assim como gerar uma má distribuição e pouca variabilidade dos pontos não dominados ao longo da fronteira de Pareto.

Em um MOO, supomos que todas as funções-objetivo são conflitantes entre si, isto é, a minimização de uma acarreta o aumento de pelo menos uma outra função. A resolução de tal problema é conhecido na literatura por combinar seus múltiplos objetivos em uma função de objetivo único.

O problema de alocação de recursos em termos de otimização do compromisso EE-SE, também denominado eficiência de recursos (RE) em redes OCDMA será formulado com o objetivo de maximizar simultaneamente o compromisso EE-SE. Portanto, apresentamos o seguinte problema de MOO:

$$\begin{aligned} \max_{\mathbf{p}} \quad & \eta_{SE} \left[ \frac{\text{bit}}{\text{s.HZ}} \right] \quad \text{e} \quad \max_{\mathbf{p}} \quad \eta_{EE} \left[ \frac{\text{bit}}{\text{J}} \right] \\ \text{s. t.} \quad & \text{(C.1)} \quad p_{\min} \leq p_i \leq p_{\max} \\ & \text{(C.2)} \quad \gamma_i \geq \gamma_i^*, \forall i \\ & \text{(C.3)} \quad r_i \geq r_{i,\min}^{\text{serv}} \end{aligned} \quad (22)$$

$\mathbf{p} = [p_1, p_2, \dots, p_K]$  é o vetor de potência alocada considerando  $K$  nós ópticos, e  $\gamma_i$  é a SINR para o  $i$ -ésimo usuário, dado por (14). No Capítulo 6, serão apresentadas estratégias de resolução para o problema multiobjetivo EE-SE através do método de MOO  $\epsilon$ -restrito combinado a métodos de programação não linear, bem como o uso de somas ponderadas para a construção do problema MOO.

### 2.3 CONCLUSÕES DO CAPÍTULO

Este capítulo apresentou breve análise do sistema para redes OCDMA-PON, bem como as principais características dos códigos 2-D MLEWHPC os quais suportam variedade de serviços multimídia. Uma rede com estas características de sistemas será utilizada nos testes numéricos exibidos nos capítulos 3, 4, 5 e 6. Também foram descritos os problemas de alocação de recursos em redes ópticas OCDMA-PON abordados nesta Tese.

### 3 ESTRATÉGIAS DE SOLUÇÃO DO PROBLEMA DE ALOCAÇÃO DE POTÊNCIA MÍNIMA

Neste capítulo são apresentadas estratégias de resolução para o problema de alocação de potência mínima descrito no Capítulo 2, Seção 2.2. Três estratégias para problemas de Programação Não Linear (PNL) são abordadas: a) a rede neural artificial de Hopfield modificada, b) o método de programação quadrática sequencial e c) o método Lagrangiano aumentado.

A Seção 3.1 descreve a solução algébrica (TARHUNI et al., 2006) para o problema de alocação de potência mínima da rede OCDMA. Já na Seção 3.2, são apresentados os métodos de otimização abordados na resolução do problema e, na Seção 3.3, são discutidos os aspectos relacionados à implementação dos métodos de otimização aplicados. Na Seção 3.4, apresentamos os parâmetros da rede utilizada para validação dos testes realizados, bem como é feita a análise dos resultados obtidos demonstrando que as metodologias estudadas são adequadas para o problema operando sob diferentes cenários de carregamento do sistema.

#### 3.1 SOLUÇÃO ALGÉBRICA DO PROBLEMA DE ALOCAÇÃO DE POTÊNCIA MÍNIMA

O problema de alocação de potência mínima apresentado na Seção 2.2.1, segundo (TARHUNI et al., 2006), pode ser expresso em notação matricial da seguinte maneira:

$$\begin{aligned}
 \min \quad & J_1(\mathbf{p}) = \mathbf{1}^T \mathbf{p} = \sum_{i=1}^K p_i \\
 \text{s. t.} \quad & \Gamma_i = \frac{G_{ii} p_i}{\sum_{j=1, j \neq i}^K G_{ij} p_j + \sigma_1^2} \geq \Gamma_i^* \\
 & p_{\min} \leq p_i \leq p_{\max}, \quad \forall i = 1, \dots, K.
 \end{aligned} \tag{23}$$

A restrição da CINR (23) pode ser escrita como:

$$[\mathbf{I} - \Lambda^* \mathbf{H}] \mathbf{p} \geq \bar{\mathbf{u}}, \quad (24)$$

sendo  $H_{ij}$  o  $ij$ -ésimo elemento da matriz interferência normalizada, dados por:

$$H_{ij} = \begin{cases} 0, & i = j; \\ \frac{G_{ij}}{G_{ii}}, & j \neq i. \end{cases}, \quad \bar{u}_i = \frac{\Gamma_i^* \sigma_i^2}{G_{ii}}, \quad \Lambda^* = \begin{pmatrix} \Gamma_1^* & \dots & 0 \\ 0 & \Gamma_2^* & \dots \\ 0 & 0 & \dots \Gamma_K^* \end{pmatrix}. \quad (25)$$

$\Lambda^*$  é uma matriz diagonal com  $\Gamma^*$  alvo como seus elementos. A solução de alocação de potência para o problema (23) pode ser explicitada utilizando o Teorema de Perron-Frobenius dado a seguir:

**Teorema 1** (*Teorema de Perron-Frobenius*) *Existe um vetor positivo associado ao máximo autovalor da matriz  $\mathbf{H}_{K \times K}$  não-negativa e irredutível.*

**Demonstração:** Ver (GANTMACHER, 1964). □

Desta forma, a solução do problema (23) existe somente se  $\frac{1}{\Gamma_{\min}}$  é um autovalor de  $\mathbf{H}$  e seu correspondente autovetor positivo  $\mathbf{p}^*$  será o vetor potência ótima.

Por outro lado, usando a primeira restrição de (23), a solução do controle de potência é o autovetor correspondente ao maior autovalor absoluto  $\lambda_{\max}$  ou o raio espectral  $\rho(\mathbf{H})$  da matriz de interferência normalizada  $\mathbf{H}$ .

O valor máximo resultante da CINR alvo satisfeito por todos os nós no mesmo tempo é

$$\Gamma_{\max} = \frac{1}{|\lambda_{\max}|}. \quad (26)$$

Logo pode-se expressar a solução do sistema (23) a partir do cômputo da matriz inversa, resultando:

$$\mathbf{p}^* = [\mathbf{I} - \Gamma_{\max} \mathbf{H}]^{-1} \mathbf{u} \quad (27)$$

sendo  $u_i = \frac{\Gamma_{\max} \sigma_i^2}{G_{ii}}$ .

## 3.2 MÉTODOS DE OTIMIZAÇÃO ABORDADOS


### 3.2.1 REDE NEURAL DE HOPFIELD

Em 1982, John Hopfield apresentou um tipo de rede neural artificial diferente daquelas fundamentadas no Perceptron (HOPFIELD, 1982). Neste modelo, a rede apre-

sentava conexões recorrentes e baseava-se num aprendizado não supervisionado com a competição entre os neurônios. Esse tipo de arquitetura de rede neural artificial apresenta as seguintes características: (i) Comportamento tipicamente dinâmico; (ii) Capacidade de memorizar relacionamentos; (iii) Possibilidade de armazenamento de informações; (iv) Facilidade de implementação analógica.

Hopfield (HOPFIELD, 1982) apresenta alguns aspectos mostrando que redes neurais recorrentes de uma única camada podem ser caracterizadas por uma função de energia relacionada aos estados de seu comportamento dinâmico. Assim, deve-se assumir que uma função de energia  $E(x)$  leve a saída da rede para pontos de equilíbrio estáveis, sendo esta a solução desejada frente a um problema específico. A função energia pode conter diversos pontos de equilíbrio considerados estáveis. Então, durante o processo de convergência da rede, a partir de alguns estados iniciais, a tendência é que a evolução de estados da rede sempre conduza na direção de um desses pontos de equilíbrio considerados estáveis. No contexto deste trabalho, a rede de Hopfield é aplicada à otimização do problema (23).

A rede de Hopfield (HOPFIELD, 1982), inicialmente proposta, tem a estrutura como mostra a Figura 5 de uma única camada em que todos os neurônios são completamente interligados, ou seja, todos os neurônios da rede são conectados a todos os outros e a si próprios onde as saídas realimentam as entradas.



**Figura 5: Rede de Hopfield.**

**Fonte: Autoria própria**

A expressão de forma simplificada que rege o comportamento em tempo contínuo de cada neurônio da rede de Hopfield é dada por:

$$\dot{u}_j(t) = -\eta u_j(t) + \sum_{i=1}^K W_{ij} v_i(t) + \iota_j^b, \quad j = 1, \dots, K \quad (28)$$

$$v_j(t) = \bar{g}(u_j(t)) \quad (29)$$

$u_j(t)$  é estado corrente do  $j$ -ésimo neurônio no método mH-NN;  $\dot{u}_j(t)$  é o estado interno do  $j$ -ésimo neurônio, ou seja, a derivada em relação ao tempo de  $u_j(t)$ ;  $v_j(t)$  é a saída do  $j$ -ésimo neurônio;  $W_{ij}$  é o valor do peso sináptico conectando o  $j$ -ésimo neurônio ao  $i$ -ésimo neurônio;  $\iota_j^b$  é o limiar (*bias*) aplicado ao  $j$ -ésimo neurônio;  $\bar{g}(\cdot)$  é uma função de ativação monótona crescente, limitando a saída do neurônio;  $\eta$  é o fator de decaimento passivo;  $x_j(t)$  é a entrada do  $j$ -ésimo neurônio no método mH-NN como na Figura 5. Observando as expressões (28) e (29) verifica-se que o comportamento da rede de Hopfield é sempre dinâmico, isto é, aplica-se um conjunto de entradas e em seguida, as saídas  $\mathbf{v}$  são calculadas e realimentam às entradas. A saída é então recalculada e o processo se repete de maneira iterativa. As sequências de iterações sucessivas produzem mudanças (cada vez menores) nas saídas da rede, até que seus valores se tornem constantes (estáveis). Assim, os passos envolvidos com a dinâmica da rede Hopfield apresentada nas expressões (28) e (29), podem ser identificados da seguinte forma:

**Em  $t = t_0$**  → entrada  $\mathbf{x}(t_0)$  gera saída  $\mathbf{v}(t_0)$ .

**Em  $t = t_1$**  → entrada  $\mathbf{x}(t_1)$  gera saída  $\mathbf{v}(t_1)$ .

**Em  $t = t_2$**  → entrada  $\mathbf{x}(t_2)$  gera saída  $\mathbf{v}(t_2)$ .

(...)

**Em  $t = t_K$**   $\mathbf{v}(t_K) = \mathbf{v}(t_{K-1})$  condição de rede estabilizada.

Logo, dado qualquer conjunto de condições iniciais  $x^{(0)}$  e impondo restrições específicas para a matriz de pesos  $\mathbf{W}$ , a finalidade é garantir a convergência para pontos de equilíbrio estáveis. Este sistema dissipa energia com o passar do tempo, em consideração às certas condições que lhe são impostas. Deve-se mostrar, deste modo, que suas derivadas temporais são sempre menores ou iguais a zero, conforme o segundo método de Lyapunov (SLOTINE; LI., 1991). Assim, uma função de Lyapunov para a rede de Hopfield, cujos neurônios são alterados um de cada vez, é definida por:

$$E(t) = -\frac{1}{2} \mathbf{v}(t)^T \mathbf{W} \mathbf{v}(t) - \mathbf{v}(t)^T \boldsymbol{\iota}^b \quad (30)$$

os pontos de equilíbrio da rede correspondem aos valores de  $\mathbf{v}(t)$  que minimizam a função de energia da rede;  $\mathbf{W}$  é a matriz de pesos;  $\boldsymbol{\iota}^b = [\iota_1^b, \iota_2^b, \dots, \iota_n^b]$  é o vetor de *bias* associado à função de energia da rede.

A partir de (30) obtém-se a expressão para as suas derivadas temporais, isto é:

$$\dot{E}(t) = \frac{dE(t)}{dt} = (\nabla_{\mathbf{v}} E(t))^T \dot{\mathbf{v}}(t) \quad (31)$$

$\nabla_{\mathbf{v}}$  é o operador gradiente em relação ao vetor  $\mathbf{v}$ . Desde que a matriz de pesos seja simétrica, ou seja,  $\mathbf{W} = \mathbf{W}^T$ , tem-se:

$$\nabla_{\mathbf{v}} E(t) = -\mathbf{W}\mathbf{v}(t) - \boldsymbol{\iota}^b. \quad (32)$$

De (28) assumindo que o termo de decaimento passivo seja nulo, conclui-se o seguinte resultado com (32):

$$\nabla_{\mathbf{v}} E(t) = -\dot{\mathbf{u}}(t). \quad (33)$$

Utilizando as relações anteriores, obtém-se a expressão para a derivada da função  $E(t)$ :

$$\begin{aligned} \dot{E}(t) &= -\dot{\mathbf{u}}(t)^T \dot{\mathbf{v}}(t) \\ &= -\sum_{j=1}^n \underbrace{(\dot{u}_j(t))^2}_i \cdot \underbrace{\frac{\partial v_j(t)}{\partial u_j(t)}}_{ii}. \end{aligned} \quad (34)$$

A parcela (i) é sempre positiva. Para a parcela (ii) escolhe-se uma função de ativação, monótona crescente, que limita a saída de cada neurônio para um intervalo pré-definido. Portanto, tem-se assim as duas condições essenciais para que o comportamento dinâmico da rede de Hopfield seja estável: (i) A matriz  $\mathbf{W}$  ser simétrica; (ii) A função de ativação  $\bar{g}(\cdot)$  deve ser monótona crescente.

Ao se estabelecer as condições acima, e dado qualquer conjunto de condições iniciais  $\mathbf{x}^{(0)}$  a rede convergirá para um ponto de equilíbrio estável. Como a rede de Hopfield é determinística, para quaisquer posições iniciais que estejam dentro da região de atração de um ponto de equilíbrio, a rede sempre convergirá assintótica para este ponto.

### 3.2.2 REDE DE HOPFIELD MODIFICADA

As redes neurais utilizadas para resolver problemas de otimização não-linear com restrição são em geral desenvolvidas utilizando parâmetros de penalidade. Os pontos de equilíbrio correspondentes às soluções do problema são obtidos através de uma escolha adequada dos parâmetros de penalidade que devem ser suficientemente grandes para garantir a convergência da rede (KENNEDY; CHUA, 1988), (VAZQUEZ et al., 1990), (VIDYASAGAR, 1992).

Entretanto, a escolha destes parâmetros é uma tarefa árdua, sendo normalmente realizada através de técnicas empíricas, as quais podem demandar um esforço computacional bastante excessivo. Além disso, a qualidade da solução final também depende do ajuste destes parâmetros.

Uma análise detalhada dos resultados apresentados em (AIYER et al., 1990) e (SILVA, 2003) demonstra que muitas vezes pontos infactíveis são apontados como soluções do problema. Com a finalidade de contornar os problemas relacionados a convergência, os autores utilizam uma nova metodologia para mapeamento de problemas de otimização não-linear restrita denominada rede de Hopfield modificada. A rede de mH-NN foi implementada com o propósito de que os pontos de equilíbrio correspondam à solução do problema de otimização não-linear restrita. As principais características desta rede são: (i) inexistência de constantes de ponderação; (ii) todas as restrições estruturais envolvidas ao problema de otimização não-linear restrita são agrupadas em um único termo de restrição; (iii) não há interferência entre termo de otimização e termo de restrição; (iv) nenhum parâmetro de iniciação é requerido para a execução da simulação.

Para PNLs, é utilizada uma função de energia  $E(t)$  composta por dois termos:

$$E(t) = E^{ot}(t) + E^{conf}(t) \quad (36)$$

$$E^{ot}(t) = -\frac{1}{2} \mathbf{v}(t)^T \cdot \mathbf{W}^{ot} \mathbf{v}(t) - \mathbf{v}(t)^T \boldsymbol{\iota}^{ot} \quad (37)$$

e

$$E^{conf}(t) = -\frac{1}{2} \mathbf{v}(t)^T \cdot \mathbf{W}^{conf} \mathbf{v}(t) - \mathbf{v}(t)^T \boldsymbol{\iota}^{conf}. \quad (38)$$


Na equação (36) os termos  $E^{ot}$  e  $E^{conf}(\cdot)$  correspondem respectivamente à função de energia a ser otimizada e a função que confina todas as restrições em um único termo. Em (37) os termos  $\mathbf{W}^{ot}$  e  $\boldsymbol{\iota}^{ot}$  correspondem à matriz de pesos associada a  $E^{ot}$  e ao vetor de *bias*. Na equação (38) os termos  $\mathbf{W}^{conf}$  e  $\boldsymbol{\iota}^{conf}$  correspondem à matriz de pesos



associada à  $E^{conf}$  e ao vetor de *bias*.

A rede tem por objetivo minimizar simultaneamente a função energia  $E^{ot}(t)$  associada à função objetivo do problema de minimização como também às funções  $E_k^{rest}$  que representam as  $k$ -ésimas restrições envolvidas no problema.

A arquitetura da rede mH-NN, cuja dinâmica é explicada por meio de três passos, é exibida na Figura 6, na rede  $\mathbf{v}$  permanece no ciclo (I) e (II) até que seja satisfeita a condição do passo (II) ( $\bar{g}(\mathbf{v}) = \mathbf{v}$ ), senão  $\mathbf{v} \leftarrow \bar{g}(\mathbf{v})$  e retorna para o passo (I); se satisfeita a condição do passo (II) então segue-se para o passo (III) onde  $\mathbf{v}$  é atualizado e realimenta o passo (I). O processo é repetido até se obter a estabilidade de  $\mathbf{v}$ .



**Figura 6:** Rede mH-NN para resolução de problemas de otimização com restrições.

**Fonte:** Autoria própria

- I**– Minimização de  $E^{conf}$ : corresponde à projeção de  $\mathbf{v}$  sobre o subespaço-válido que confina todas as restrições impostas pelo problema. Esta operação realiza uma minimização indireta de  $E^{conf}$  com intuito de satisfazer às restrições do problema;
- II**– Aplicação de uma função de ativação do tipo rampa simétrica, restringindo  $\mathbf{v}$  dentro de um hipercubo pré-definido;
- III**– Minimização de  $E^{ot}$  na direção de optimalidade  $\Delta \mathbf{v}$ , a qual foi obtida com tamanho de passo  $\Delta t$ .

A dinâmica da rede mH-NN é o melhor exemplo de rede recorrente onde as saídas de uma camada neural na etapa (III) são realimentadas às suas entradas na etapa

(I). Ou seja, ela mostra a convergência da rede mH-NN, cuja dinâmica de operação é implementada por meio dos passos (I)-(III).

Considerando-se o seguinte problema de otimização, composto de  $n$  restrições de igualdade a  $n$  variáveis, ou seja,

$$\begin{aligned} \min \quad & E^{ot} = f(\mathbf{v}) \\ \text{s. t.} \quad & E^{conf}(\mathbf{v}) : h_i(\mathbf{v}) = 0, \quad \forall i = 1, \dots, K \\ & z_i^{\min} \leq v_i \leq z_i^{\max} \end{aligned} \quad (39)$$

$v_i, z_i^{\min}, z_i^{\max} \in \mathbb{R}$  e as funções  $f(\mathbf{v})$  e  $\mathbf{h}(\mathbf{v})$  são contínuas e diferenciáveis, representando a função custo e as restrições de igualdade em um PNL respectivamente; os vetores  $\mathbf{z}^{\min}$  e  $\mathbf{z}^{\max}$  definem os limites inferiores e superiores para cada uma das componentes do vetor  $\mathbf{v}$ . As restrições representam o conjunto fechado convexo em  $R^K$  onde o vetor  $\mathbf{v}$  deve permanecer a fim de representar uma solução válida para o problema de otimização apresentado.

Uma solução para o problema (23) pode ser obtida pela rede mH-NN, cuja implementação do subespaço-válido garante a satisfação das condições definidas pelas restrições de igualdade. Ademais, o hipercubo inicial representado pelas restrições de desigualdade é diretamente mapeado pela função rampa-simétrica definida por:

$$g_i(v_i) = \begin{cases} z_i^{\max}, & \text{se } v_i > z_i^{\max}, \\ v_i, & \text{se } z_i^{\min} \leq v_i \leq z_i^{\max}, \\ z_i^{\min}, & \text{se } v_i < z_i^{\min}. \end{cases} \quad (40)$$

Esta função é usada como função de ativação neural, isto é,

$$v_i \in [z^{\min}, z^{\max}].$$

A matriz de projeção  $\mathbf{W}^{conf}$  é calculada por meio da projeção de  $\mathbf{v}$ , obtida a partir da minimização de  $E^{ot}(\mathbf{v}) = f(\mathbf{v})$ , para o subespaço tangente à superfície delimitada pelas restrições.

Uma equação para  $\mathbf{W}^{conf}$  pode ser definida por (LUENBERGER; YE, 2008):

$$\mathbf{W}^{conf} = \mathbf{I} - \nabla \mathbf{h}(\mathbf{v})^T (\nabla \mathbf{h}(\mathbf{v}) \nabla \mathbf{h}(\mathbf{v})^T)^{-1} \nabla \mathbf{h}(\mathbf{v}), \quad (41)$$

$$\nabla \mathbf{h}(\mathbf{v}) = \begin{bmatrix} \frac{\partial h_1(\mathbf{v})}{\partial v_1} & \frac{\partial h_1(\mathbf{v})}{\partial v_2} & \cdots & \frac{\partial h_1(\mathbf{v})}{\partial v_n} \\ \frac{\partial h_2(\mathbf{v})}{\partial v_1} & \frac{\partial h_2(\mathbf{v})}{\partial v_2} & \cdots & \frac{\partial h_2(\mathbf{v})}{\partial v_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial h_p(\mathbf{v})}{\partial v_1} & \frac{\partial h_p(\mathbf{v})}{\partial v_2} & \cdots & \frac{\partial h_p(\mathbf{v})}{\partial v_n} \end{bmatrix} = \begin{pmatrix} \nabla h_1(\mathbf{v})^T \\ \nabla h_2(\mathbf{v})^T \\ \vdots \\ \nabla h_p(\mathbf{v})^T \end{pmatrix}. \quad (42)$$

A equação do subespaço-válido apresentada em (43):

$$\mathbf{v} \leftarrow [\mathbf{I} - \nabla \mathbf{h}(\mathbf{v})^T (\nabla \mathbf{h}(\mathbf{v}) \cdot \nabla \mathbf{h}(\mathbf{v})^T)^{-1} \nabla \mathbf{h}(\mathbf{v}) \mathbf{v}] + \boldsymbol{\iota}^{conf}. \quad (43)$$

Utilizando-se dos resultados da teoria de Lyapunov em (43) tem-se por finalidade garantir a estabilidade do sistema não-linear e induzir a convergência da rede para os pontos de equilíbrio que representam uma solução para o sistema.

Pela definição do Jacobiano, quando tende ao ponto de equilíbrio ( $\mathbf{v}^e$ ), implica-se que  $\mathbf{v}^e = \mathbf{0}$ . Neste caso o valor de  $\boldsymbol{\iota}^{conf}$  deve ser também nulo para satisfazer a condição de equilíbrio, ou seja:

$$\mathbf{v}^e = \mathbf{v}(t) = \mathbf{v}(t + \Delta t) = \mathbf{0}. \quad (44)$$

Assim, a restrição de igualdade em (39) é aproximada da seguinte maneira:

$$\mathbf{h}(\mathbf{v}) \cong \mathbf{h}(\mathbf{v}^e) + \nabla \mathbf{h}(\mathbf{v})(\mathbf{v} - \mathbf{v}^e), \quad (45)$$

$$\mathbf{h}(\mathbf{v}) = [h_1(\mathbf{v}), h_2(\mathbf{v}), \dots, h_p(\mathbf{v})]^T.$$

Na vizinhança do ponto de equilíbrio, em que  $\mathbf{v}^e = \mathbf{0}$ , vale a relação:

$$\lim_{\mathbf{v} \rightarrow \mathbf{v}^e} \frac{\|\mathbf{h}(\mathbf{v})\|}{\|\mathbf{v}\|} = 0. \quad (46)$$

Das relações acima, atualizando (43) tem-se:

$$\mathbf{v} \leftarrow (\mathbf{v} - \nabla \mathbf{h}(\mathbf{v})^T (\nabla \mathbf{h}(\mathbf{v}) \cdot \nabla \mathbf{h}(\mathbf{v})^T)^{-1} \nabla \mathbf{h}(\mathbf{v}) \mathbf{v}). \quad (47)$$

A expressão de (43) representa a etapa (I) da topologia da rede mH-NN apresentada na Figura 6, sendo substituído aqui por (47). Assim, a aplicação sucessiva da etapa (I) e (II) garante que  $\mathbf{v}$  convirja para o ponto de equilíbrio que satisfaça todas as restrições do problema de otimização não linear. Ainda, os parâmetros  $\mathbf{W}^{ot}$  e  $\boldsymbol{\iota}^{ot}$  associados a  $E^{ot}$  são definidos com o objetivo de que a solução ótima corresponda à minimização de  $E^{ot}$ .

Considera-se que a região de operação na qual o vetor  $\mathbf{v}$  está contido é limitada pelo hipercubo definido pela função de ativação (40). A equação nodal descrevendo o comportamento dinâmico desta rede é obtida de (28) para  $\eta = 0$ , pois as alterações nos neurônios são realizadas de forma síncrona, ou seja, todos os neurônios serão alterados simultaneamente, e  $\mathbf{v}(t) = \mathbf{u}(t)$ , ou seja:

$$\dot{v}_j(t) = \sum_{j=1}^K W_{ij}^{ot} v_j(t) + \iota_j^b, j = 1, \dots, K \quad (48)$$

$$v_j(t) = g(u_j(t)). \quad (49)$$

Os pontos de equilíbrio da rede podem ser calculados considerando os seguintes valores para  $\mathbf{W}^{ot}$  e  $\boldsymbol{\iota}^{ot}$ :

$$\boldsymbol{\iota}^{ot} = - \left[ \frac{\partial f(\mathbf{v})}{\partial v_1}, \frac{\partial f(\mathbf{v})}{\partial v_2}, \dots, \frac{\partial f(\mathbf{v})}{\partial v_K} \right]^T,$$

$$\mathbf{W}^{ot} = \mathbf{0}.$$

Para aplicar mH-NN ao problema (23) são introduzidas variáveis de folga no vetor  $\mathbf{p}$ ,  $\mathbf{p}^+ = (\mathbf{p}, \mathbf{q})$ , de forma que a restrição  $\Gamma(\mathbf{p}) \leq \Gamma^*$  torne-se uma restrição de igualdade, ou seja, podemos definir a restrição da seguinte forma:  $\Gamma^+(\mathbf{p}^+) = \Gamma(\mathbf{p}) - \Gamma^* + \mathbf{q} = 0$ . Considere também a função  $J_1^+$  definida como  $J_1^+(\mathbf{p}^+) = J_1(\mathbf{p})$ . A dinâmica da rede mH-NN para o problema de minimização da potência em redes OCDMA é exibida na Figura 7.

O pseudocódigo descrito no Algoritmo 1 ilustra os passos básicos da rede mH-NN aplicada na solução do problema (23) a fim de encontrar o consumo de potência de transmissão para cada usuário e cenário de operação da rede OCDMA factível.

### 3.2.3 PROGRAMAÇÃO QUADRÁTICA SEQUENCIAL

O método de programação quadrática sequencial é baseado em gradientes e consiste na aproximação sequencial do problema de PNL como um problema de programação quadrática. Ao contrário de outros métodos que tentam convertê-lo em uma sequência de subproblemas de otimização irrestrita, o SQP tenta resolver o problema de otimização de forma iterativa. A solução em cada etapa é obtida pela solução de uma aproximação não linear. Em nosso caso em (23),  $J_1(\mathbf{p})$  é substituído por uma aproximação quadrática da




Figura 7: Rede mH-NN para resolução do problema de minimização da potência em redes OCDMA.

Fonte: Autoria própria

**Algoritmo 1:** mH-NN para controle de potência em OCDMA

- 1 Escolha: um ponto inicial  $\mathbf{p}$  com valores aleatórios, tolerância  $\zeta > 0$  e  $\Delta t \in (0, 1)$ ;
- 2 repita
  - 3 repita
    - 4 Obter o valor de  $\Gamma^+(\mathbf{p}^+)$ ;
    - 5 Obter a matriz Jacobiana  $\nabla\Gamma^+(\mathbf{p}^+)$ ;
    - 6 Atualizar o valor de  $\mathbf{p}^+$  a partir de  $\mathbf{p}^+ \leftarrow (\mathbf{p}^+ - \nabla\Gamma^+(\mathbf{p}^+))^T (\nabla\Gamma^+(\mathbf{p}^+). \nabla\Gamma^+(\mathbf{p}^+)^T)^{-1} \nabla\Gamma^+(\mathbf{p}^+)$ ;
    - 7 Aplicar a função de ativação;
  - 8 até  $\bar{g}(\mathbf{p}^+) = \mathbf{p}^+$ ;
  - 9 Calcule  $\boldsymbol{\iota}^{ot} = -\nabla J_1^+(\mathbf{p}^+)$ ;
  - 10 Atualizar o valor de  $\mathbf{p}^+ \leftarrow \mathbf{p}^+ + \Delta t(\mathbf{W}^{ot}\mathbf{p}^+ + \boldsymbol{\iota}^{ot})$
- 11 até  $\|\Delta t(\mathbf{W}^{ot}\mathbf{p}^+ + \boldsymbol{\iota}^{ot})\| < \zeta$ ;

função Lagrangiana  $\mathcal{L}$  e as restrições de desigualdade não-lineares são substituídas por aproximações lineares.

A principal ideia na abordagem de otimização do SQP é a formulação de um subproblema de programação quadrática baseado em uma aproximação quadrática da função Lagrangiana:

$$\mathcal{L}(\mathbf{p}, \boldsymbol{\mu}) = J_1(\mathbf{p}) + \sum_{i=1}^K \mu_i [\Gamma_i^* - \Gamma_i(\mathbf{p})]. \quad (50)$$

Assim, a cada iteração  $k$ , o método SQP resolve o seguinte problema de programação quadrática:

$$\begin{aligned} \min_{\mathbf{d}} \quad & J_1(\mathbf{p}^k) + \nabla J_1(\mathbf{p}^k)^\top \mathbf{d} + \frac{1}{2} \mathbf{d}^\top \nabla^2 \mathcal{L}(\mathbf{p}^k) \mathbf{d} \\ \text{s.t.} \quad & -\nabla \Gamma_i(\mathbf{p}^k)^\top \mathbf{d} + \Gamma_i^* - \Gamma_i(\mathbf{p}^k) \geq 0, \quad i = 1 \dots K, \end{aligned} \quad (51)$$

$\nabla^2$  denota o operador matriz Hessiana,  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$  é definida por:

$$\nabla^2 \mathcal{L}(\mathbf{p}^k) = \nabla^2 J(\mathbf{p}^k) - \sum_{i=1}^K \mu_i^k \nabla^2 \Gamma_i(\mathbf{p}^k),$$

com o objetivo de determinar a melhor direção de busca na  $k$ -ésima iteração, denotada por  $\mathbf{d}^k$  a partir (do ponto  $\mathbf{p}^k$ ) como a solução de (51) e associada ao  $i$ -ésimo multiplicador de Lagrange  $\mu_i^k$  na  $k$ -ésima iteração; em seguida, atualiza-se para o próximo ponto  $\mathbf{p}^{k+1}$  que é obtido por meio da projeção de  $\mathbf{p}^k + a_k \mathbf{d}^k$  na caixa  $p_{\min} \leq p_i \leq p_{\max}$ , sendo  $a_k \in (0, 1]$  o tamanho do passo  $k$ -ésima iteração na direção de busca.

Como no método de Newton, embora o valor ideal do passo seja  $a_k = 1$ , os valores de  $a_k \in (0, 1]$  são determinados para garantir as propriedades gerais de convergência do método.  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$  é uma aproximação positiva definida da matriz Hessiana da função Lagrangiana, que pode ser substituída por uma aproximação numérica (NO-CEDAL; WRIGHT, 2006).

Assim, usando o método SQP, um problema não linear pode ser resolvido em menos iterações, com complexidade semelhante a um problema quadrático. Uma das razões para isso é que, devido aos limites da região factível, o otimizador pode tomar decisões sobre as direções de busca e o tamanho do passo. O Algoritmo 2 resume o método SQP.

**Algoritmo 2:** SQP – Programação Quadrática Sequencial

- 1 Escolha um ponto inicial  $\mathbf{p}^0$ , aproximação  $\mu_0$  para os multiplicadores e tolerância  $\zeta > 0$  ;
- 2 Faça  $k = 0$ ;
- 3 **repita**
- 4     Avalie  $J_1(\mathbf{p}^k)$ ,  $\nabla J_1(\mathbf{p}^k)$ ,  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$ ,  $\Gamma_i(\mathbf{p}^k)$  e  $\nabla \Gamma_i(\mathbf{p}^k)$ ;
- 5     Resolva (51) para obter  $\mathbf{d}^k$  e  $\boldsymbol{\mu}^{k+1}$ ;
- 6      $\mathbf{p}^{k+1} \leftarrow \mathcal{P}(\mathbf{p}^k + a_k \mathbf{d}^k)$  sendo  $\mathcal{P}$  é o operador de projeção ortogonal na caixa  $p_{\min} \leq p_i \leq p_{\max}$ ;
- 7      $k \leftarrow k + 1$ ;
- 8 **até**  $\|\mathbf{p}^{k+1} - \mathbf{p}^k\| < \zeta$ ;

No Algoritmo 2 o operador projeção ortogonal  $\mathcal{P}$  é definido por:

$$\mathcal{P}(\mathbf{p}) = \bar{\mathbf{p}}, \quad \text{sendo } \bar{p}_i = \begin{cases} p_{\min}, & p_i \leq p_{\min} \\ p_{\max}, & p_i \geq p_{\max} \\ p_i, & \text{caso contrário.} \end{cases} \quad (52)$$

Alguns resultados adicionais para o método de programação quadrática sequencial podem ser encontrados em (NOCEDAL; WRIGHT, 2006).

### 3.2.4 MÉTODO DO LAGRANGIANO AUMENTADO

No problema de programação não linear definido em (23),  $\Omega$  um subconjunto simples de  $\mathbb{R}^K$ , na formulação do problema de alocação da potência mínima definido como:

$$\Omega = \{\mathbf{p} \in \mathbb{R}^K \mid p_{\min} \leq p_i \leq p_{\max}\}.$$

As funções  $J_1(\mathbf{p}) : \mathbb{R}^K \rightarrow \mathbb{R}$ ,  $\Gamma_i(\mathbf{p}) : \mathbb{R}^K \rightarrow \mathbb{R}^K$ , possuem primeiras derivadas contínuas em  $\mathbb{R}^K$ .

Para nosso problema de alocação de potência mínima, dado um parâmetro de penalidade  $\rho$  positivo, e aproximações  $\mu_i \geq 0$  para os multiplicadores de Lagrange, a função Lagrangiana aumentada  $\mathcal{A}_\rho$  pode ser definida como:

$$\mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu}) = J_1(\mathbf{p}) + \frac{\rho}{2} \sum_{i=1}^K \left[ [\Gamma_i^* - \Gamma_i(\mathbf{p})]^+ + \frac{\mu_i}{\rho} \right]^2 \quad (53)$$

$$[\alpha]^+ = \max[0, \alpha].$$

Os principais passos do ALM são:

---

**Passo 1** Inicialização: dados os multiplicadores iniciais  $\boldsymbol{\mu}_0$  e valor de penalidade  $\rho$ ;

**Passo 2** Resolva o problema Lagrangiano aumentado associado,  $\min_{\mathbf{x} \in \Omega} \mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu})$ ;

**Passo 3** Verifique se o ponto obtido no Passo 2 satisfaz as condições de optimalidade de Karush-Kuhn-Tucker para o problema, caso contrário, vá para a próxima etapa.

**Passo 4** De acordo com os resultados das etapas anteriores, atualize os multiplicadores e o parâmetro de penalidade,

Atualize os multiplicadores de Lagrange:

$$\mu_i^{k+1} = \max\{0, \mu_i^k + \rho_k(\Gamma_i^* - \Gamma_i(p^k))\}, \quad i = 1, \dots, m \quad \text{e} \quad \mu_i^{k+1} \in [0, \mu_{\max}].$$

Atualize os parâmetros de penalidade:

$$V_i^k = \max \left\{ \Gamma_i^* - \Gamma_i(p^k), -\frac{\mu_i^k}{\rho_k} \right\}.$$

$$\text{Se } \|V^k\|_\infty \leq \tau \|V^{k-1}\|_\infty \quad \text{então} \quad \rho_{k+1} = \rho_k.$$

Caso contrário  $\rho_{k+1} = \nu \cdot \rho_k$ , sendo  $\nu > 1$ .

Voltar para o Passo 1.

---

O vetor  $V^k$  mede a factibilidade e a complementariedade na  $k$ -ésima iteração, enquanto o parâmetro  $\tau$  representa o nível de decréscimo esperado e  $\nu$  indica o incremento aplicado em  $\rho$  (ANDREANI et al., 2007a).

Geralmente, no ALM, o parâmetro de penalidade é colocado para ser pequeno nas primeiras iterações externas, porque os parâmetros grandes tendem a produzir subproblemas mal condicionados. Como consequência, as primeiras iterações tendem a privilegiar a otimização de  $J_1$ .

O método descrito no Algoritmo 3 é uma versão simplificada do método Lagrangiano aumentado. No Algoritmo 3,  $\varepsilon_k$  é o parâmetro de tolerância do  $k$ -ésimo subproblema. A condição apresentada em (54) implica que  $\mathbf{p}^k$  é uma solução aproximada de  $\min_{\mathbf{p} \in \Omega} \mathcal{A}(\mathbf{p}, \boldsymbol{\mu}^k)$ . Para determinar  $\mathbf{p}^k$  aplicamos um método do tipo quase-Newton, a saber o método BFGS (NOCEDAL; WRIGHT, 2006). Uma análise a respeito da con-



vergência do ALM pode ser encontrada em (BIRGIN et al., 2011), (ANDREANI et al., 2007a), (NOCEDAL; WRIGHT, 2006).

<b>Algoritmo 3:</b> ALM – Método do Lagrangiano aumentado	
1	Parâmetros de Entrada: $\mu_{\max} > 0$ , $\mu_i^1 \in [0, \mu_{\max}]$ , $\forall i = 1, \dots, m$ , $\zeta > 0$ , $\{\varepsilon_k\} \subset \mathbb{R}_+$ de modo que $\lim_{k \rightarrow \infty} \varepsilon_k = 0$ ;
2	Faça $k \leftarrow 1$ ;
3	<b>repita</b>
4	Calcular com o método BFGS $\mathbf{p}^k \in \mathbb{R}^K$ satisfazendo
	$\left\  \mathcal{P}(\mathbf{p}^k - \nabla \mathcal{A}(\mathbf{p}^k, \mu^k)) - \mathbf{p}^k \right\  \leq \varepsilon_k, \quad (54)$
	sendo $\mathcal{P}$ o operador projeção na caixa $p_{\min} \leq p_i \leq p_{\max}$ . Atualize os multiplicadores de Lagrange e o parâmetro de penalidade;
5	$k \leftarrow k + 1$ ;
6	<b>até</b> $\ \mathbf{p}^{k+1} - \mathbf{p}^k\  < \zeta$ ;

### 3.3 IMPLEMENTAÇÃO, FACTIBILIDADE E COMPLEXIDADE DO ALGORITMO

Nesta seção são desenvolvidos os aspectos relevantes sobre a implementação dos dois métodos de PNL, bem como a rede mH-NN descritos na Seção 3.2, para determinação da solução do problema de alocação de potência mínima em (23).

#### 3.3.1 ASPECTOS DE IMPLEMENTAÇÃO DOS ALGORITMOS ANALISADOS

São discutidos na sequência, os principais aspectos em relação à implementação dos métodos considerados.

**Implementação: SQP.** O método SQP é inicializado com multiplicadores nulos e uma aproximação aleatória para  $\mathbf{p}$  na hiper caixa  $[p_{\min}, p_{\max}]$ . Na implementação do Algoritmo 2, as derivadas foram calculadas por diferenças finitas e o subproblema quadrático foi resolvido usando um método de pontos interiores para problemas quadráticos convexos (NOCEDAL; WRIGHT, 2006).

**Implementação: ALM.** O algoritmo ALM é inicializado com uma aproximação aleatória na hiper caixa  $p_i^0 \in [p_{\min}, p_{\max}]$ , iniciando-se os multiplicadores com zeros e o parâmetro de penalidade inicial  $\rho^0 = 10$  e os parâmetros  $\nu = 10$ ,  $\tau = 0, 1$ ; Para resolução do subproblema do passo 3 no Algoritmo 3, utilizamos um método do tipo quase-Newton, a saber o método BFGS (NOCEDAL; WRIGHT, 2006).

**Implementação: mH-NN.** O algoritmo mH-NN é inicializado por uma aproximação aleatória

na hiper caixa  $p_i^0 \in [p_{\min}; p_{\max}]$ , seguindo os três passos descritos no diagrama da Figura 6.  $\Delta t = 0,1$  foi adotado para implementações distribuídas e nenhuma exigência de treinamento. Não houve a necessidade de implementações mais sofisticadas para o tamanho do passo  $\Delta t$  devido aos bons resultados obtidos para o valor fixo adotado.

### 3.3.2 CRITÉRIO DE PARADA E FACTIBILIDADE

O mesmo critério de parada foi considerado para todos os algoritmos de alocação de potência analisados. Portanto, se após o resultado da  $k$ -ésima iteração externa,  $\mathbf{p}^k$  factível e

$$\xi = \|\mathbf{p}^k - \mathbf{p}^{k-1}\| < \zeta = 10^{-6}, \quad (55)$$

o algoritmo finaliza a execução, atingindo a convergência.

A factibilidade no contexto do problema de controle de potência OCDMA é considerada como:

$$\mathcal{F}_i^k = [\Gamma_i^* - \Gamma_i]^+ = \max\{0, \Gamma_i^* - \Gamma_i\} \text{ se } p_{\min} \leq p_i^k \leq p_{\max}, \text{ para toda iteração e } i = 1, \dots, K. \quad (56)$$

Assim, o valor nulo da factibilidade  $\mathcal{F}^k = \max\{\mathcal{F}_1^k, \mathcal{F}_2^k, \dots, \mathcal{F}_K^k\}$  na  $k$ -ésima iteração indica que o vetor de potência  $\mathbf{p}^k$  satisfaz as restrições do problema (23).

### 3.3.3 ERRO MÉDIO QUADRÁTICO NORMALIZADO

A qualidade da solução alcançada pelos algoritmos de alocação de potência em uma iteração pode ser medida pelo grau de proximidade com a solução ótima  $\mathbf{p}^*$ , sendo quantificada através do erro quadrático médio normalizado (NMSE – *Normalized Mean Square Error*) quando o equilíbrio é atingido. A qualidade da solução alcançada por um algoritmo específico na solução do problema (23) na  $k$ -ésima iteração é simplesmente definida por (MARQUES et al., 2016):

$$\text{NMSE}[t, k] = \mathbb{E} \left[ \frac{\|\mathbf{p}_t[k] - \mathbf{p}^*\|^2}{\|\mathbf{p}^*\|^2} \right], \quad (57)$$

$\|\cdot\|^2$  denota a norma Euclidiana ao quadrado entre o vetor  $\mathbf{p}_t[k]$  para o vetor solução ótimo  $\mathbf{p}^*$  na  $k$ -ésima iteração da  $t$ -ésima realização, e  $\mathbb{E}[\cdot]$  é o operador esperança. Esta medida também será analisada no contexto deste trabalho.

### 3.3.4 ROBUSTEZ ALGORÍTMICA

A robustez do algoritmo  $\mathcal{R}$  é definida como a razão entre o número de sucessos de convergência  $\text{cS}$  e o número total de realizações do processo  $\mathcal{T}$ :

$$\mathcal{R} = \frac{\text{cS}}{\mathcal{T}} \cdot 100 \quad [\%]. \quad (58)$$

O evento de sucesso da convergência é confirmado quando o critério de parada e a factibilidade são alcançados simultaneamente.

## 3.4 RESULTADOS NUMÉRICOS

Nesta seção o objetivo é analisar por meio de testes numéricos o comportamento da rede neural mH-NN na resolução do problema de alocação mínima de potência e compará-la com os métodos de programação não linear, levando-se em consideração topologias de redes ópticas realísticas baseadas em códigos 2-D MLEWHPC descritos na Seção 2.3. A arquitetura de rede OCDMA utilizada é similar àquelas apresentadas em (WONG, 2012), (DURAND; ABRAO, 2017), (PENDEZA MARTINEZ et al., 2019).

Aplicamos os três algoritmos para diferentes números de nós de uma rede OCDMA considerando os valores dos parâmetros apresentados na Tabela 1. As implementações são completamente distribuídas e nenhum treinamento é necessário. A CINR alvo adotada de 20dB foi escolhida para alcançar a transmissão adequada em uma rede de taxa única, resultando em um BER menor que o limite tolerável  $10^{-12}$ . Além disso, a escolha do tamanho da rede considerada para análise numérica nesta seção leva em consideração dois cenários: o Cenário A, que representa um carregamento médio do sistema com  $K = \{8, 16, 32\}$  nós; enquanto o segundo Cenário B é uma rede óptica com cargas mais desafiadoras,  $K = \{48, 64, 128\}$  e níveis diferentes de QoS foram considerados.

Os resultados das simulações foram realizados utilizando o software MatLab 8.0 executado no sistema operacional de 64 bits Windows 10 Home Language, versão 1803, processador Intel(R)Core i5-8250U @CPU 1.60GHz, 8GB de RAM instalada.

### 3.4.1 OTIMIZAÇÃO DA ALOCAÇÃO DA POTÊNCIA (CENÁRIO A)

Para o primeiro cenário, os três algoritmos utilizados levaram em consideração diferentes números de usuários de uma rede OCDMA, cujos parâmetros são descritos na Tabela 1. A Tabela 2 descreve valores relevantes referentes ao desempenho dos três

**Tabela 1: Valores de parâmetros adotados.**

Valores de	Parâmetros	Unidade
Ordem de Modulação	$M = 2$	(Binary)
Ineficiência do Transponder	$\iota = 2, 7$	[W/Gbps]
Ruído Branco std	$\sigma = 0,032$	[dB]
Constante de Planck	$h = 6,63 \times 10^{-34}$	[J/Hz]
Período de Chip	$T_c = 9$	[ps]
Comprimento do link	[4, 100]	[km]
Potência Max. do Laser	$p_{\max} = 20$	[dBm]
Potência Min. do Laser	$p_{\min} = (p_{\max} - 90)$	[dBm]
<b>Cenário A: taxa única</b>		
Número de usuários	$K \in \{8, 16, 32\}$	
Taxa Min. de usuário	$r_{\min}^{\text{serv}} = 30$	[Mbps]
Comprimento da sequência	$F_i = \frac{T_b}{T_c} = 121$	
Max. BER aceitável	$\text{BER} \leq 10^{-12}$	
CINR	$\Gamma^* = 20$	[dB]
<b>Cenário B: taxa única, diferentes QoS</b>		
Número de usuários	$K \in \{48, 64, 128\}$	
Comprimento da sequência OCDMA	$F_i = \frac{T_b}{T_c} = 121$	
Max. BER aceitável	$\text{BER} \leq 10^{-12}$	
Classe I: CINR <sup>(I)</sup>	$\Gamma^{(I)*} = 17$	[dB]
Classe II: CINR <sup>(II)</sup>	$\Gamma^{(II)*} = 20$	[dB]
Classe III: CINR <sup>(III)</sup>	$\Gamma^{(III)*} = 22$	[dB]
Taxa Min. de usuário por Classe	$r_{\min}^{\text{serv}} = 25, 30 \text{ ou } 35$	[Mbps]
<b>Inicialização do Algoritmo</b> (Todos algoritmos) e Convergência		
Vetor potência de inicialização	$p_i^0 \sim \mathcal{U}[p_{\min}; p_{\max}]$	
Número máximo de iterações	$\mathcal{I} = 10$	
Critério de convergência	$\mathcal{F} \leq 10^{-4}$ e $\xi < 10^{-6}$ , $\mathbf{p}$ factibilidade	

métodos de alocação de potência, incluindo tempo de execução, valor mínimo de soma das potências  $J_1(\mathbf{p})$ , número necessário de iterações para convergência, medida de factibilidade  $\mathcal{F}$ , número de operações de ponto flutuante por segundo (FLOPS – *Floating-Point Operations Per Second*), NMSE normalizado (57) e somas das taxas  $\sum_{i=1}^K r_i$ , com  $r_i \geq r_{\min}^{\text{serv}}$ . O número de FLOPS foi calculado através de uma adaptação do programa Contour FLOPS de Hang Qian <sup>1</sup>.

A Tabela 2 mostra que todos os métodos convergiram para pontos factíveis e alcançam os valores de alocação ótima de potência para o Cenário A.

**Tabela 2: Tempo de execução, número de iterações externas para convergência, factibilidade para os três algoritmos, FLOPS, NMSE e soma das taxas considerando o aumento do número de nós ópticos.**

$$\Gamma^* = 20\text{dB} \quad (r_{\min}^{(\text{III})} = 30\text{Mbps}) \text{ e } \bar{r}_i^{(\text{III})} \approx 34, 34 \text{ Mbps.}$$

Método	Tempo [s]	$J_1(\mathbf{p})$ [W]	Iterações	Factibilidade $\mathcal{F}$	FLOPS	NMSE	$\sum_{i=1}^K r_i$ [Mbps]
<b>8 usuários</b>							
ALM	0,34078	$7,901001 \times 10^{-5}$	6	$3,459311 \times 10^{-5}$	$2,9615 \times 10^5$	0,49289	$2,74721 \times 10^2$
SQP	0,01577	$7,90197 \times 10^{-5}$	3	<b><math>2,74802 \times 10^{-14}</math></b>	$6,5850 \times 10^4$	0,25633	$2,74751 \times 10^2$
mH-NN	<b>0,01215</b>	$7,90105 \times 10^{-5}$	<b>2</b>	$4,78985 \times 10^{-6}$	<b><math>2,8885 \times 10^4</math></b>	<b><math>2,28502 \times 10^{-12}</math></b>	$2,7475 \times 10^2$
<b>16 usuários</b>							
ALM	0,59639	$4,70084 \times 10^{-4}$	6	$1,82361 \times 10^{-5}$	$1,4106 \times 10^6$	0,37642	$5,5970 \times 10^2$
SQP	0,01965	$4,70114 \times 10^{-4}$	3	<b><math>3,40500 \times 10^{-11}</math></b>	$4,1945 \times 10^5$	0,33332	$5,4950 \times 10^2$
mH-NN	<b>0,01559</b>	$4,70094 \times 10^{-4}$	<b>2</b>	$8,66522 \times 10^{-6}$	<b><math>2,0925 \times 10^5</math></b>	<b><math>1,49264 \times 10^{-11}</math></b>	$5,4942 \times 10^2$
<b>32 usuários</b>							
ALM	0,98670	0,01869	6	$2,7581 \times 10^{-6}$	$2,6283 \times 10^7$	0,30801	$1,0989 \times 10^3$
SQP	0,34545	0,01869	3	$1,1180 \times 10^{-10}$	<b><math>2,9736 \times 10^6</math></b>	0,22872	$1,0990 \times 10^3$
mH-NN	<b>0,01508</b>	0,01869	<b>2</b>	<b><math>9,8134 \times 10^{-18}</math></b>	$3,2326 \times 10^6$	<b><math>4,44322 \times 10^{-7}</math></b>	$1,0990 \times 10^3$

Os melhores níveis de factibilidade foram obtidos pelos métodos SQP e mH-NN e os melhores valores de NMSE foram obtidos pelo método mH-NN, com vantagem para o método mH-NN, quando o valor de  $K$  aumenta. Para 8 e 16 usuários, mH-NN e SQP tiveram quantias próximas de FLOPS, enquanto mH-NN foi ligeiramente mais rápido que SQP considerando o tempo de execução. Especificamente para maior dimensão de problema, ou seja, para  $K \geq 32$  usuários, SQP alcançou menor número de FLOPS. No entanto, o método mH-NN alcançou convergência, exigindo menor tempo de processamento. Pode-se observar que mH-NN e SQP tiveram um desempenho muito próximo, enquanto o ALM consome um maior número de FLOPS e, portanto, consumiu mais tempo para a convergência.

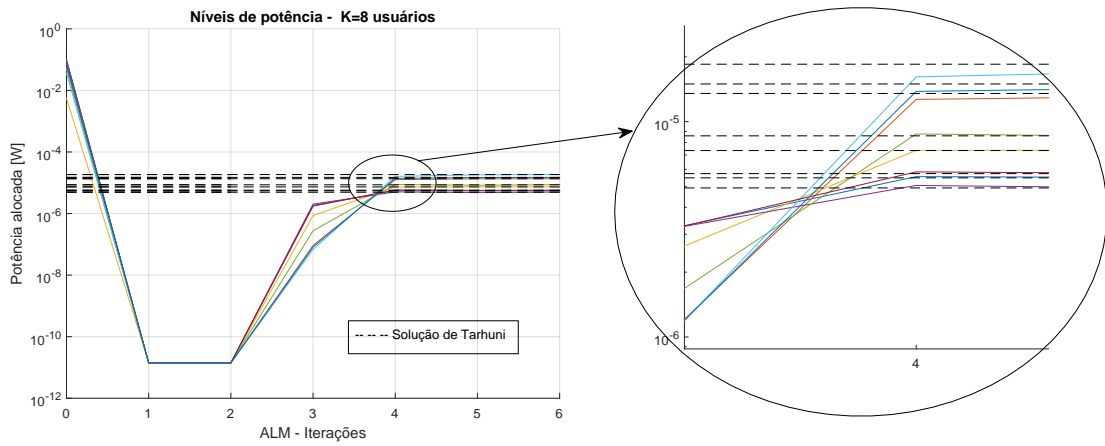
<sup>1</sup>Disponível para download em [se.mathworks.com/matlabcentral/fileexchange/50608-counting-the-floating-point-operations-flops](https://se.mathworks.com/matlabcentral/fileexchange/50608-counting-the-floating-point-operations-flops)

Finalmente, os métodos SQP e mH-NN atingiram praticamente os mesmos níveis de soma das taxas, ou seja,  $\sum_{i=1}^K r_i \geq K \cdot r_{\min}^{\text{serv}}$  para todos os valores de usuário, enquanto o ALM apresenta pouca diferença para os valores de soma das taxas devido à degradação do desempenho de factibilidade, quando comparado aos outros dois métodos. Note que para a restrição adotada  $r_{\min}^{\text{serv}} = 30\text{Mbps}$ , o consumo de potência do laser obtido é suficiente para atingir uma taxa média por usuário de  $\bar{r}_i = 34,34\text{Mbps}$ . Esse resultado garante que a rede óptica opere com uma certa folga acima do valor mínimo estabelecida para  $r_{\min}^{\text{serv}}$ , enquanto todos os usuários satisfazem suas respectivas QoS.

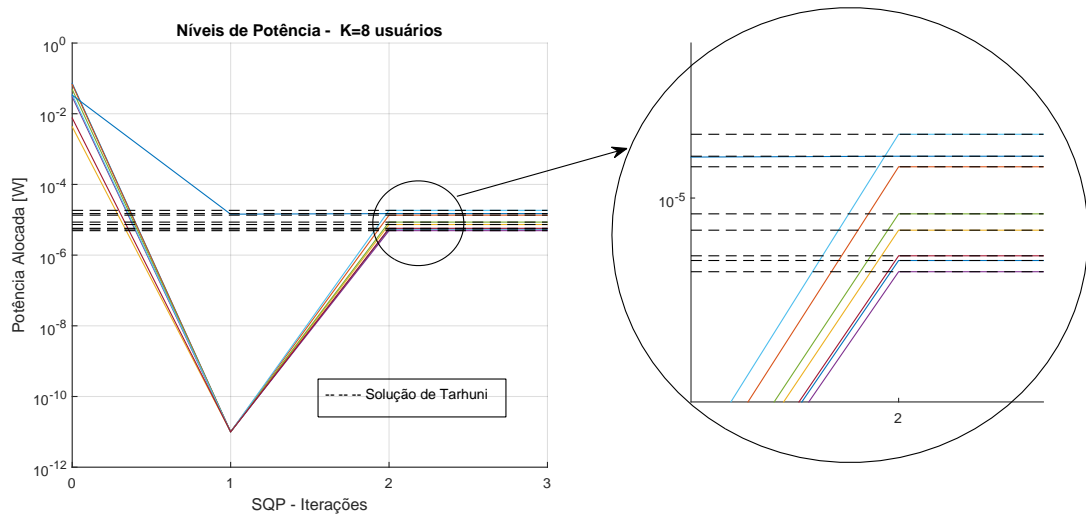
A Figura 8 representa a evolução da convergência dos níveis de potência individuais para os três métodos de alocação de potência na resolução (23) em comparação com a solução da matriz inversa obtida por (TARHUNI et al., 2006). Na Figura 8 (a), pode-se observar que o ALM começa a se aproximar dos níveis de potência individuais da solução após a quarta iteração e a convergência ocorre na sexta iteração. Enquanto o método SQP na Figura 8(b) é capaz de atingir os níveis de potência ótima já na segunda iteração e satisfaz os critérios de convergência na terceira iteração. Finalmente, a Figura 8(c) mostra o método mH-NN alcançando a solução logo após a primeira iteração e converge na segunda iteração.

A Figura 9(a) representa a evolução da soma-potência  $J_1(\mathbf{p})$  ao longo das iterações. Pode-se notar que, independentemente do número de usuários, o algoritmo mH-NN atinge a alocação de potência mínima exigida logo na primeira iteração. Por outro lado, o SQP aproxima-se da convergência após a segunda iteração e o ALM aproxima-se da solução de potência ótima após a terceira iteração. A Figura 9(b) representa a evolução da soma das taxas de usuário junto com as iterações para os três métodos discutidos. Como resultado, o comportamento é semelhante ao gráfico da soma das potências na Figura 9(a). Pode-se ver que os métodos ALM e SQP, no início das iterações, obtiveram valores muito diferentes do valor ótimo da soma das taxas.

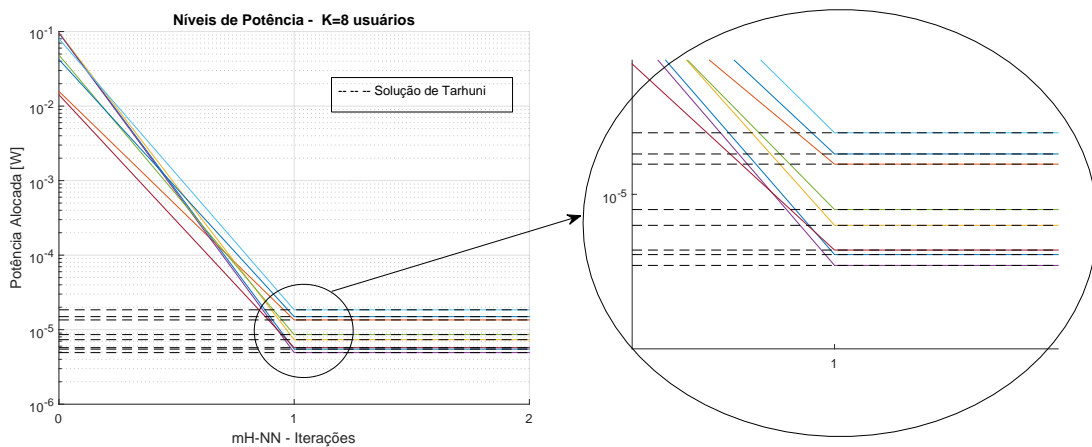
A análise da convergência dos métodos de programação não-linear ilustrada na Figura 8 e 9(a) evidencia que esses métodos, nas primeiras iterações, podem preferencialmente buscar melhores valores da função objetivo do que de factibilidade. Esse comportamento é descrito na literatura como a voracidade na busca pela minimização da função objetivo, o que já foi relatado em (CASTELANI et al., 2010) para o ALM, mas considerando a dimensão das redes tratadas. Esta característica não afetou a convergência do método para as diferentes dimensões consideradas neste trabalho,  $K \in \{8, 16, 32, 48, 64, 128\}$  usuários. No entanto, podemos destacar que o ALM exigiu um número maior de iterações



a) Algoritmo ALM



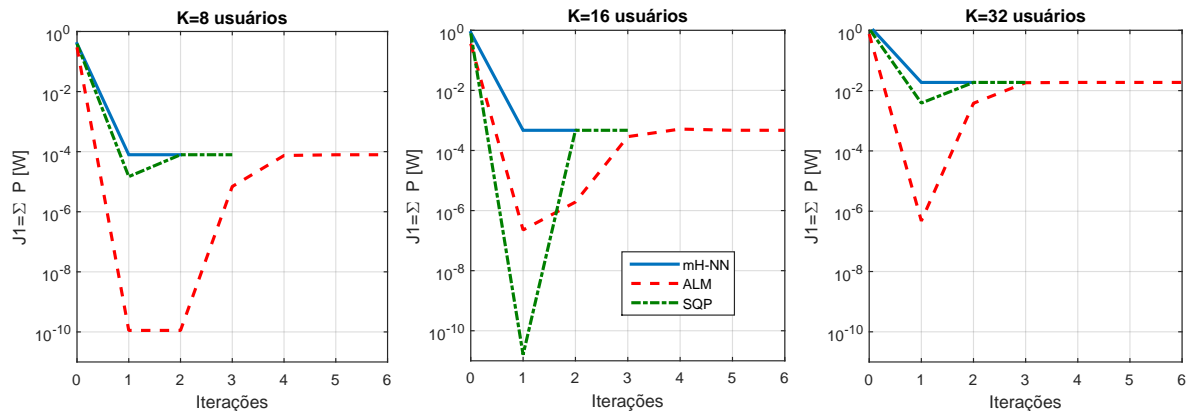
b) Algoritmo SQP




c) Algoritmo mH-NN

**Figura 8: Evolução dos níveis individuais de potência até o equilíbrio no Cenário A considerando  $K = 8$  usuários: a) ALM; b) SQP; c) mH-NN algoritmos.**

Fonte: Autoria própria



(a) Níveis de soma de potências



(b) Níveis de soma das taxas

Figura 9: Soma da potência (a) e soma das taxas (b) alocação através das iterações para  $K = 8, 16$  e  $32$  usuários no Cenário A.

Fonte: Autoria própria



para convergir quando comparado ao método SQP. Por outro lado, o método mH-NN demonstrou um comportamento distinto em relação aos métodos da PNL, aproximando-se mais rápido da convergência, tipicamente após a primeira iteração o que o torna um candidato promissor na resolução do problema posto em (23).

### 3.4.2 OTIMIZAÇÃO DO CONTROLE DE POTÊNCIA COM DIFERENTES NÍVEIS DE QOS (CENÁRIO B)

Nesta seção, o problema de alocação de potência mínima é definido para um sistema OCDMA com diferentes níveis de QoS, considerando os parâmetros descritos na Tabela 1 para o Cenário B e redes com  $K = 48, 64$  e  $128$  usuários. Este cenário foi analisado para três níveis diferentes de QoS determinados por classes (associados a diferentes sistemas OCDMA de taxa única atingível), nomeadamente as Classes I, II e III definidas pela CINR, respectivamente:

$$\Gamma^* = 17\text{dB} \quad (r_{\min}^{(I)}); \quad 20\text{dB} \quad (r_{\min}^{(II)}); \quad \text{e} \quad 22\text{dB} \quad (r_{\min}^{(III)}).$$

Como no Cenário A, nesta subseção os três algoritmos de atribuição de potência são comparados em termos de tempo de execução, solução de potência mínima, número de iterações, factibilidade, FLOPS, NMSE e taxas de dados atingíveis, conforme descrito nas Tabelas 3, 4 e 5. Além disso, há um aumento significativo nos níveis de potência alocados quando o número de usuários aumenta, implicação direta de maior nível de MAI, ou quando é necessária uma QoS mais alta. Como esperado, isso implica em uma alocação crescente da soma de potência devido aos vários usuários requerendo acesso simultâneo à rede OCDMA, aumentando a MAI junto aos usuários. Pode-se notar que no Cenário B, os três métodos mantiveram desempenho semelhante para as três classes de serviço, Classe I, II e III àquelas obtidas no Cenário A (taxa única). Os métodos SQP e mH-NN apresentam valores de tempo de execução semelhantes, enquanto atingem os melhores níveis de factibilidade. Além disso, o mH-NN é capaz de atingir melhores níveis de NMSE, devido ao fato de que, já na primeira iteração, o método foi capaz de alcançar aproximações adequadas para a solução, mesmo sob carregamento elevados de  $K = 128$  usuários. Em termos de FLOPs, o SQP obteve melhores resultados para  $K = 128$  usuários na Classe I e nas Classes II e III para  $K = 64$  e  $128$  usuários quando comparado ao mH-NN.

Assim, podemos observar que o SQP apresenta melhor complexidade computacional quando consideramos  $K = 64$  e  $128$  usuários. Por sua vez, o ALM apresentou

os piores valores para o NMSE, pois consome maior número de iterações para atingir a mesma QoS. Considerando a soma de taxas alcançável, pode-se observar o comportamento semelhante ao Cenário A, sendo que SQP e mH-NN apresentam valores muito próximos, e ALM uma pequena diferença, provavelmente devido ao seu desempenho inferior quanto à factibilidade.

Como no Cenário A, note que para a restrição adotada de taxa mínima por classe  $r_{\min}^{\text{serv}}$ , o consumo de potência do laser obtido é suficiente para atingir uma taxa média por usuário de  $\bar{r}_i$ . Esse resultado garante que a rede óptica opera com uma certa folga acima do valor mínimo estabelecido para  $r_{\min}^{\text{serv}}$ , enquanto todos os usuários satisfazem suas respectivas QoS por classe.

**Tabela 3: Classe I– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para  $K = 48, 64, 128$  nós ópticos.**

(a) Classe I –  $\Gamma^* = 17\text{dB}$  ( $r_{\min}^{(i)} = 25\text{Mbps}$ ) e  $\bar{r}_i^{(i)} \approx 29, 49$  Mbps.

Método	Tempo [s]	$J_1 = \sum p_i$ [W]	Iterações	Factibilidade $\mathcal{F}$	FLOPS	NMSE	$\sum_{i=1}^K r_i$ [Mbps]
<b>48 usuários</b>							
ALM	1,21379	0,026371	6	$1,24862 \times 10^{-6}$	$3,5609 \times 10^{+8}$	0,36453	$1,4155 \times 10^{+3}$
SQP	<b>0,03135</b>	0,026371	4	$7,06701 \times 10^{-13}$	<b><math>9,5138 \times 10^{+6}</math></b>	0,14921	$1,4155 \times 10^{+3}$
mH-NN	0,03266	0,026371	<b>3</b>	<b><math>5,48562 \times 10^{-18}</math></b>	$2,2936 \times 10^{+7}$	<b><math>2,67154 \times 10^{-9}</math></b>	$1,4155 \times 10^{+3}$
<b>64 usuários</b>							
ALM	1,65431	0,035138	6	$1,38161 \times 10^{-6}$	$9,4509 \times 10^{+8}$	0,35719	$1,8874 \times 10^{+3}$
SQP	0,08348	0,035138	4	$1,61612 \times 10^{-12}$	<b><math>2,2146 \times 10^{+7}</math></b>	0,24360	$1,8874 \times 10^{+3}$
mH-NN	<b>0,05468</b>	0,035138	<b>3</b>	<b><math>6,49071 \times 10^{-18}</math></b>	$5,7321 \times 10^{+7}$	<b><math>5,33412 \times 10^{-9}</math></b>	$1,8874 \times 10^{+3}$
<b>128 usuários</b>							
ALM	2,02370	0,13220	7	$9,88553 \times 10^{-5}$	$3,9875 \times 10^{+9}$	0,39053	$3,7748 \times 10^{+3}$
SQP	<b>0,15053</b>	0,13200	<b>3</b>	$1,53822 \times 10^{-12}$	<b><math>1,7241 \times 10^{+8}</math></b>	0,05997	$3,7748 \times 10^{+3}$
mH-NN	0,34171	0,13200	<b>3</b>	<b><math>6,490744 \times 10^{-18}</math></b>	$4,8104 \times 10^{+8}$	<b><math>3,19617 \times 10^{-9}</math></b>	$3,7748 \times 10^{+3}$

A Figura 10 mostra a evolução da soma das potências ao longo das iterações externas para os três algoritmos de alocação de potência operando sob o sistema OCDMA de Classes I, II e III, respectivamente. De fato, considerando a Figura 10(a), pode-se notar que, independentemente do elevado número de usuários no Cenário B ( $K \geq 48$  usuários), os algoritmos SQP e mH-NN são capazes de atingir valores muito próximos da potência mínima requerida na segunda iteração ainda, enquanto o ALM apresenta

Tabela 4: Classe II– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para  $K = 48, 64, 128$  nós ópticos.

(b) Classe II –  $\Gamma^* = 20\text{dB}$  ( $r_{\min}^{(II)} = 30\text{Mbps}$ ) e  $\bar{r}_i^{(II)} \approx 34, 34$  Mbps.

Método	Tempo [s]	$J_1 = \sum p_i$ [W]	Iterações	Factibilidade $\mathcal{F}$	FLOPS	NMSE	$\sum_{i=1}^K r_i$ [Mbps]
<b>48 usuários</b>							
ALM	1,73390	0,05262	6	$1,27104 \times 10^{-6}$	$4,3685 \times 10^{+8}$	0,33348	$1,6485 \times 10^{+3}$
SQP	<b>0,03134</b>	0,05262	<b>3</b>	$7,39512 \times 10^{-12}$	<b><math>9,5230 \times 10^{+6}</math></b>	0,10153	$1,6485 \times 10^{+3}$
mH-NN	0,03260	0,05262	<b>3</b>	<b><math>1,15068 \times 10^{-17}</math></b>	$2,4285 \times 10^{+7}$	<b><math>6,49577 \times 10^{-9}</math></b>	$1,6485 \times 10^{+3}$
<b>64 usuários</b>							
ALM	1,91301	0,07011	6	$6,95347 \times 10^{-4}$	$1,1431 \times 10^{+9}$	0,33092	$2,1980 \times 10^{+3}$
SQP	0,08343	0,07012	<b>3</b>	$1,50302 \times 10^{-11}$	<b><math>2,2149 \times 10^{+7}</math></b>	0,14114	$2,1980 \times 10^{+3}$
mH-NN	<b>0,05468</b>	0,07012	<b>3</b>	<b><math>1,04083 \times 10^{-17}</math></b>	$5,7321 \times 10^{+7}$	<b><math>1,51221 \times 10^{-8}</math></b>	$2,1980 \times 10^{+3}$
<b>128 usuários</b>							
ALM	2,48559	0,26679	7	$5,58532 \times 10^{-4}$	$4,9978 \times 10^{+9}$	0,39589	$4,4017 \times 10^{+3}$
SQP	<b>0,15053</b>	0,26345	<b>3</b>	$7,52932 \times 10^{-12}$	<b><math>1,7534 \times 10^{+8}</math></b>	0,03146	$4,3960 \times 10^{+3}$
mH-NN	0,17014	0,26345	<b>3</b>	<b><math>1,09713 \times 10^{-17}</math></b>	$4,5572 \times 10^{+8}$	<b><math>3,73725 \times 10^{-9}</math></b>	$4,3960 \times 10^{+3}$

Tabela 5: Classe III– Tempo de execução, Soma de potência, número de iterações para a convergência, factibilidade, FLOPS, NMSE, soma das taxas e taxa média ( $\bar{r}_i$ ) para  $K = 48, 64, 128$  nós ópticos.

(c) Classe III –  $\Gamma^* = 22\text{dB}$  ( $r_{\min}^{(III)} = 35\text{Mbps}$ ) e  $\bar{r}_i^{(III)} \approx 37, 60$  Mbps.

Método	Tempo [s]	$J_1 = \sum p_i$ [W]	Iterações	Factibilidade $\mathcal{F}$	FLOPS	NMSE	$\sum_{i=1}^K r_i$ [Mbps]
<b>48 usuários</b>							
ALM	1,05472	0,08342	6	$3,55791 \times 10^{-7}$	$3,4363 \times 10^{+8}$	0,31702	$1,8046 \times 10^{+3}$
SQP	0,03901	0,08342	<b>3</b>	$2,41023 \times 10^{-11}$	<b><math>9,5851 \times 10^{+6}</math></b>	0,05154	$1,8046 \times 10^{+3}$
mH-NN	<b>0,03052</b>	0,08342	<b>3</b>	<b><math>1,20122 \times 10^{-17}</math></b>	$2,2936 \times 10^{+7}$	<b><math>7,56132 \times 10^{-9}</math></b>	$1,8046 \times 10^{+3}$
<b>64 usuários</b>							
ALM	1,420707	0,11116	6	$1,43765 \times 10^{-6}$	$9,7314 \times 10^{+8}$	0,30859	$2,4061 \times 10^{+3}$
SQP	<b>0,098363</b>	0,11116	<b>3</b>	$7,34822 \times 10^{-11}$	<b><math>2,1428 \times 10^{+7}</math></b>	0,08301	$2,4061 \times 10^{+3}$
mH-NN	0,105133	0,11116	<b>3</b>	<b><math>1,551583 \times 10^{-17}</math></b>	$5,4137 \times 10^{+7}$	<b><math>2,56962 \times 10^{-8}</math></b>	$2,4061 \times 10^{+3}$
<b>128 usuários</b>							
ALM	2,734116	0,41761	7	$2,36749 \times 10^{-4}$	$4,8290 \times 10^{+9}$	0,31848	$4,8122 \times 10^{+3}$
SQP	<b>0,215497</b>	0,41761	<b>3</b>	$4,23523 \times 10^{-11}$	<b><math>1,7381 \times 10^{+8}</math></b>	0,01831	$4,8122 \times 10^{+3}$
mH-NN	0,242005	0,41761	<b>3</b>	<b><math>1,55134 \times 10^{-17}</math></b>	$4,5573 \times 10^{+8}$	<b><math>5,34532 \times 10^{-9}</math></b>	$4,8122 \times 10^{+3}$

novamente dificuldades nas primeiras iterações para alcançar a convergência devido a sua característica de voracidade, como já visto no Cenário A. Além disso, verificando as Figuras 10(b) e 10(c) para as Classes II e III, respectivamente, pode-se notar que, independentemente do número de usuários que SQP e mH-NN estão muito próximos em termos de número de iterações para a convergência. A mesma tendência é confirmada em termos da soma das taxas para este cenário; A Figura 11 exhibe a evolução da soma das taxas em relação às iterações para as Classes I, II e III.

Ao resolver o problema de potência mínima (em  $\mathbf{p}^*$ ), observamos que o valor de  $\Gamma_i$  coincide com  $\Gamma_i^*$ , portanto, o valor de CINR para cada usuário é mínimo. Por outro lado, em  $\mathbf{p}^*$ , notamos que a soma das taxas é maior que  $Kr_{i,\min}$ . Esse resultado mostra que o vetor de potência mínima para os valores mínimos QoS atende a taxa de serviço mínima com alguma pequena folga.

### 3.4.3 ANÁLISE DE COMPLEXIDADE

A qualidade das soluções obtidas pelos três algoritmos é avaliada através da métrica NMSE apresentada em Tabelas 2, 3, 4 e 5. A Figura 12 também mostra a análise da evolução do NMSE como uma função do número de iterações para o Cenário A considerando sistemas com usuários de  $K = 8, 16$  e  $32$ . Podemos observar que os melhores níveis de NMSE ocorrem para SQP e mH-NN. Esse comportamento foi também confirmado no cenário B.

A Figura 13 e as Tabelas 2 e 4 destacam o desempenho da rede mH-NN em comparação com o SQP para  $K = \{8, 16, 32, 48, 64, 128\}$  usuários e sua superioridade sobre o ALM para os outros casos testados. Pode-se observar que a implementação do algoritmo mH-NN é bastante simples, no sentido de que esse método não requer treinamento prévio e não gera subproblemas de otimização, como pode ser observado nos outros dois métodos de otimização ALM e SQP representando de fato uma solução promissora do ponto de vista de implementabilidade.

Para trazer mais conhecimento sobre a complexidade dos três algoritmos, em relação aos três métodos analisados, apresentamos na Tabela 6 um resumo da robustez do algoritmo, medida conforme definido em (58), considerando o Cenário B com taxa de QoS 22dB por 100 realizações. Essa configuração é selecionada, pois representa a maior dificuldade entre os cenários considerados. Portanto, para o restante das combinações de classes e cenários, os três métodos facilmente alcançaram convergência total. A robustez obtida mostrou que os métodos SQP e mH-NN obtiveram sucesso total na convergência no

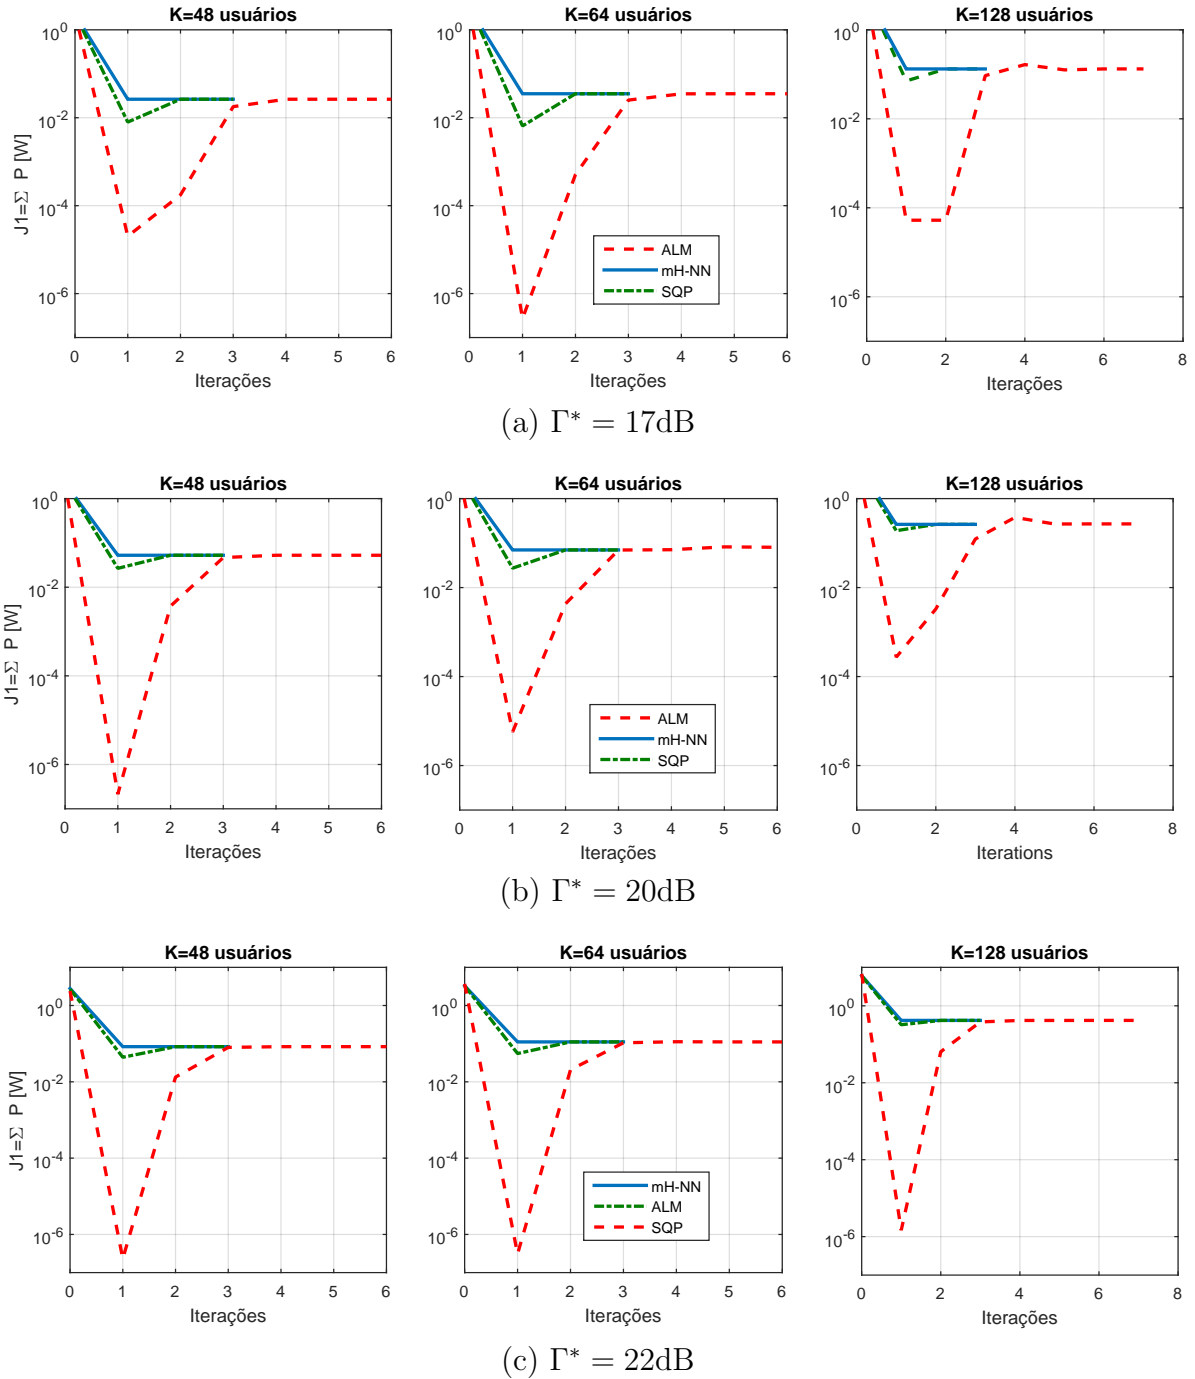


Figura 10: Níveis de soma de potências para  $K = 48, 64$  e  $128$  usuários e diferentes  $\Gamma^* \in [17, 20, 22]\text{dB}$ .

Fonte: Autoria própria

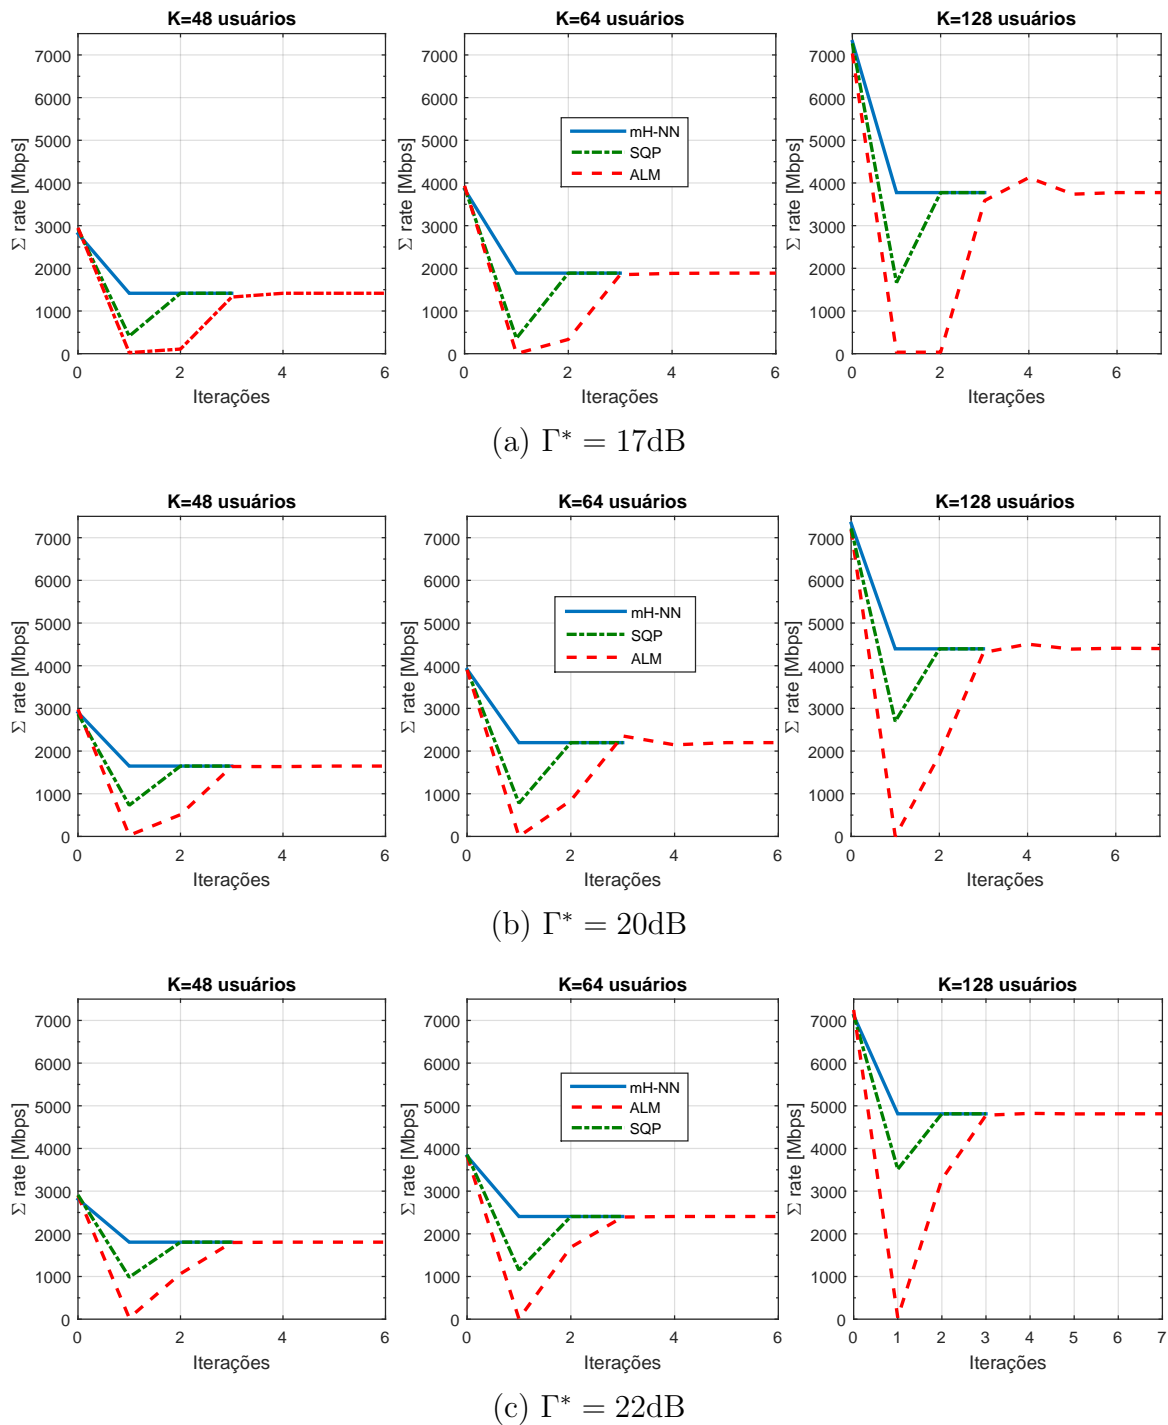


Figura 11: Alocação de soma das taxas para  $K = 48; 64$  e  $128$  usuários (cenário B) com diferentes CINR alvos: a)  $\Gamma^* = 17$  dB; b)  $\Gamma^* = 20$  dB, e c)  $\Gamma^* = 22$  dB.

Fonte: Autoria própria

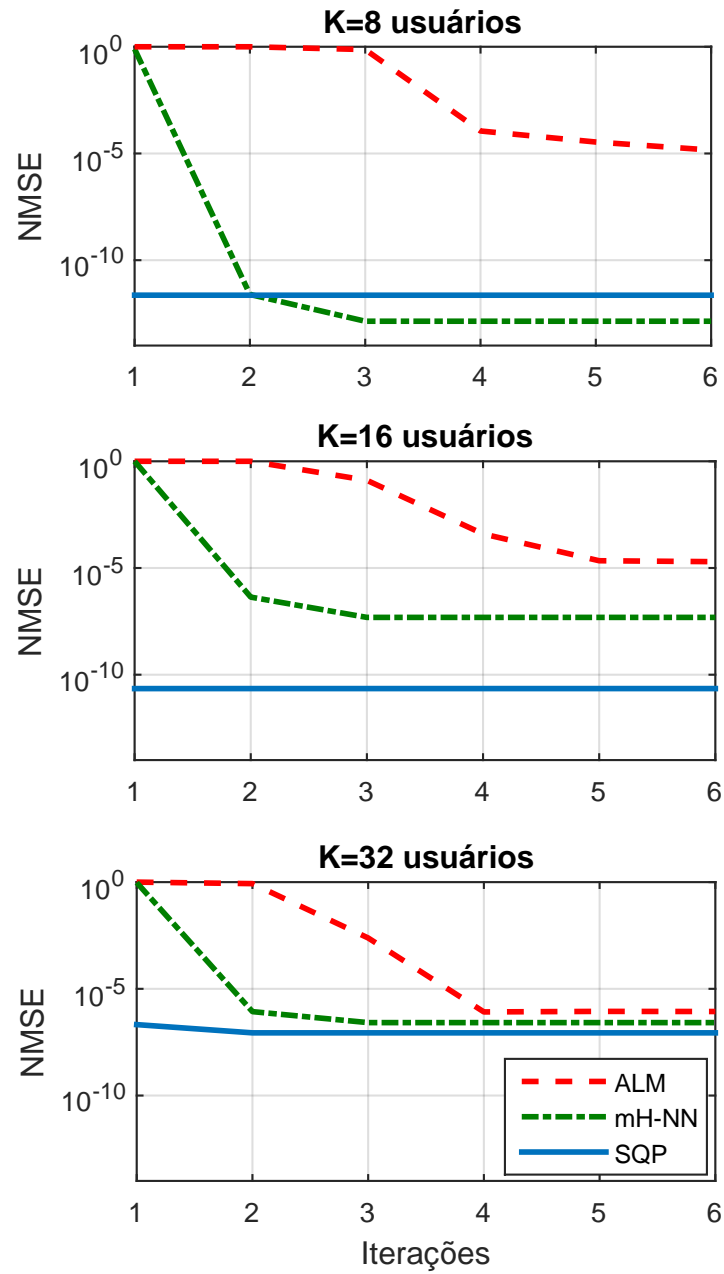



Figura 12: Evolução da NMSE dos métodos em relação ao vetor potência  $p^*$  para  $K = [8, 16, 32]$  usuários.

Fonte: Autoria própria



**Figura 13:** Tempo de Execução para os três métodos considerando  $K = \{8, 16, 32, 64, 128\}$  usuários e nível de QoS de 20 dB.

Fonte: Autoria própria

cenário de elevados carregamentos ( $K > 64$ ), enquanto o ALM conseguiu convergir para soluções aceitáveis na maioria das realizações. Quando não alcançou a convergência, isso ocorreu porque a solução alcançada pelo método não resulta em um nível de factibilidade  $\mathcal{F} \leq 10^{-4}$ , de acordo com o critério de factibilidade estipulado. Além disso, o critério de parada foi mantido neste contexto, isto é, dado em (55), enquanto o número máximo de iterações externas  $\mathcal{I} = 10$  foi adotado.

**Tabela 6:** Robustez dos algoritmos ALM, SQP e mH-NN para o problema de alocação de potência em (23) sobre  $\mathcal{T} = 100$  realizações, considerando o nível de QoS de 22dB.

Usuários	$\mathcal{R}$ -ALM	$\mathcal{R}$ -SQP	$\mathcal{R}$ -mH-NN
48	100%	100%	100%
64	98%	100%	100%
128	93%	100%	100%

No equilíbrio, a solução de alocação de potência do sistema dada em (25), a matriz  $-\mathbf{\Gamma}^*\mathbf{H}$  pode ter entradas próximas de zero, sendo que é obtida através da matriz de ganho e do CINR de destino. Como resultado, quando a soma da matriz  $(\mathbf{I} - \mathbf{\Gamma}^*\mathbf{H})$  é realizada, algumas informações podem ser perdidas devido à ordem de magnitude das entradas da



matriz  $(-\mathbf{\Gamma}^*\mathbf{H})$ . Portanto, para a resolução de (6) através da inversão da matriz, devido ao fenômeno de propagação de erros, principalmente considerando redes com grande número de usuários, ou seja,  $K \geq 48$  usuários, a solução Tarhuni (25) não obtém os níveis de factibilidade atingidos pelos métodos mH-NN e SQP, conforme mostrado na Tabela 7.

Portanto, o valor adotado para o critério de parada ( $10^{-4}$ ) estabelecidos para medir a qualidade das soluções alcançadas por cada algoritmo durante o teste indicou que os valores de factibilidade maiores que ( $10^{-4}$ ) poderiam impactar significativamente (negativamente) nos níveis de potência, como pode ser visto na Tabela 7.

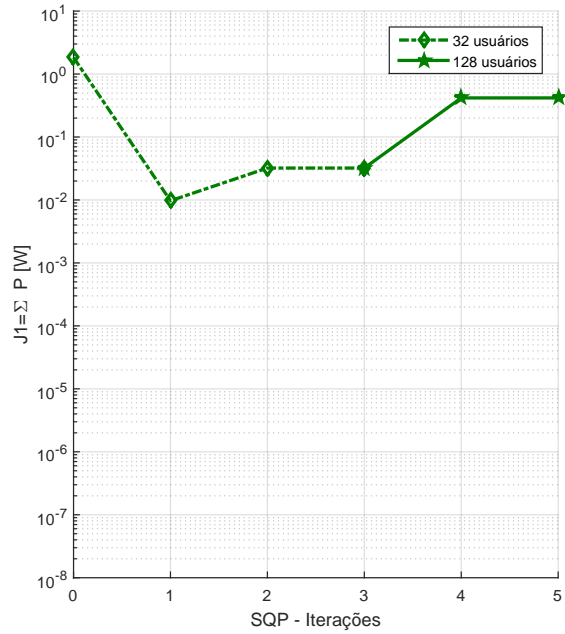
**Tabela 7: Classe C – Soma de potência e factibilidade atingível a partir de (25) para aumentar o número de nós ópticos.**

# Usuários	$J_1(\mathbf{p})$ [mW]	$\mathcal{F}$ (mH-NN)	Soma de potência Tarhuni [mW]	$\mathcal{F}$ (Tarhuni)
48	83,420	$1,20122 \times 10^{-17}$	83,38	$2,514140 \times 10^{-4}$
64	111,16	$1,55158 \times 10^{-17}$	111,01	$3,901331 \times 10^{-4}$
128	417,61	$1,55134 \times 10^{-17}$	417,36	$6,007099 \times 10^{-4}$


### 3.4.3.1 ANÁLISE DE DESEMPENHO DINÂMICO

As variações de potência na rede estão relacionadas aos efeitos lineares e não lineares associados à fibra óptica, bem como aos efeitos de acoplamento da potência do canal, que são influenciados pela topologia da rede, variação de tráfego e física dos amplificadores ópticos, como adição dinâmica e remoção de canais. Além disso, há os efeitos da imprevisibilidade de penalidades variantes no tempo, como efeitos de polarização (SANTOS et al., 2018).


Nesta subseção, estendemos a análise de robustez de algoritmos de alocação de potência mínima analisando um cenário de alocação mais desafiador: número maior de usuários e diferentes requisitos de QoS; portanto, para emular este cenário dinâmico, modificações *on fly* foram introduzidas nas configurações operacionais da rede óptica, cujos parâmetros operacionais ainda são considerados os mesmos da Tabela 1, levando em conta a adição dinâmica de canais. Para esta análise, após a convergência dos três métodos considerando 32 usuários e nível de QoS de 22 dB, o número de usuários foi incrementando abruptamente em 400% atingindo 128 usuários ativos na rede OCDMA. Deseja-se analisar a capacidade e a velocidade de recuperação dos algoritmos até o novo equilíbrio em termos de potência alocada.



a) SQP



b) Hopfield



c) ALM

Figura 14: Soma da potência alocada pelos algoritmos SQP, mH-NN e ALM em tempo real, aumentando o número de usuários em 400%.

Fonte: Autoria própria

Na Figura 14, pode-se observar que após o reinício com 128 usuários, os métodos SQP, mH-NN e ALM consumiram respectivamente 2, 2 e 6 iterações para alcançar convergência total no novo equilíbrio de alocação de potência. Além disso, o comportamento do ALM revela que, ao levar em conta o reinício do método, o mesmo não aproveitou a solução de alocação de potência anterior para 32 usuários, consumindo 6 iterações para alcançar a convergência. Por outro lado, SQP e mH-NN requereram apenas duas iterações para atingir plenamente o novo equilíbrio.

Para avaliar a capacidade dos algoritmos de alocação de potência restabelecerem o equilíbrio de potência após uma perturbação, considerou-se uma perturbação na potência óptica do  $i$ -ésimo usuário, modelada como:

$$p_i[n] = |\alpha^n \cdot \text{sen}(1,5\pi \cdot n)| + p_i^\circ, \quad n \neq 0, \quad (59)$$

$\alpha = 0,65$  e  $p_i$  a potência nominal transmitida para o  $i$ -ésimo caminho óptico no equilíbrio anterior à perturbação,  $n$  representa a iteração atual e  $p_i^\circ$  o valor mínimo de perturbação.

Para fins ilustrativos, a Figura 15 mostra a função de perturbação (59) considerando  $p_i^\circ = 0,1\text{W}$ . Pode-se ver que o efeito da perturbação tende a desaparecer à medida que se aumenta o valor de  $n$ . Essa perturbação foi considerada na primeira metade das iterações, ou seja,  $2 \leq n \leq 7$  considerando que foram adotadas sob regime de perturbação,  $\mathcal{I} = 15$  iterações para os métodos, com  $K = 128$  usuários e QoS de 22dB. Pode-se notar que os três métodos de alocação de potência OCDMA são capazes de recuperar a perturbação introduzida em (59), restabelecendo o equilíbrio de convergência para a alocação de potência ótima  $\mathbf{p}^*$ , mas com efeitos de perturbação no processo de convergência, notado principalmente nos instantes de iteração do começo onde a perturbação é inserida. Na verdade, o método baseado em mH-NN atende ao critério de convergência muito cedo, após 10 iterações, enquanto o ALM atinge a convergência após 14 iterações e o SQP após 12 iterações. Assim, podemos ver que mH-NN precisava de 1 iteração para alcançar o equilíbrio e 3 mais para convergir seguindo os valores de  $\mathcal{F}$  e  $\xi$  definidos na Tabela 1.

Na Figura 16, está apresentada a evolução da CINR máxima para as modificações *on fly* apresentadas na Figura 14 e a evolução da máxima CINR para a perturbação de potência descrita na Figura 15.

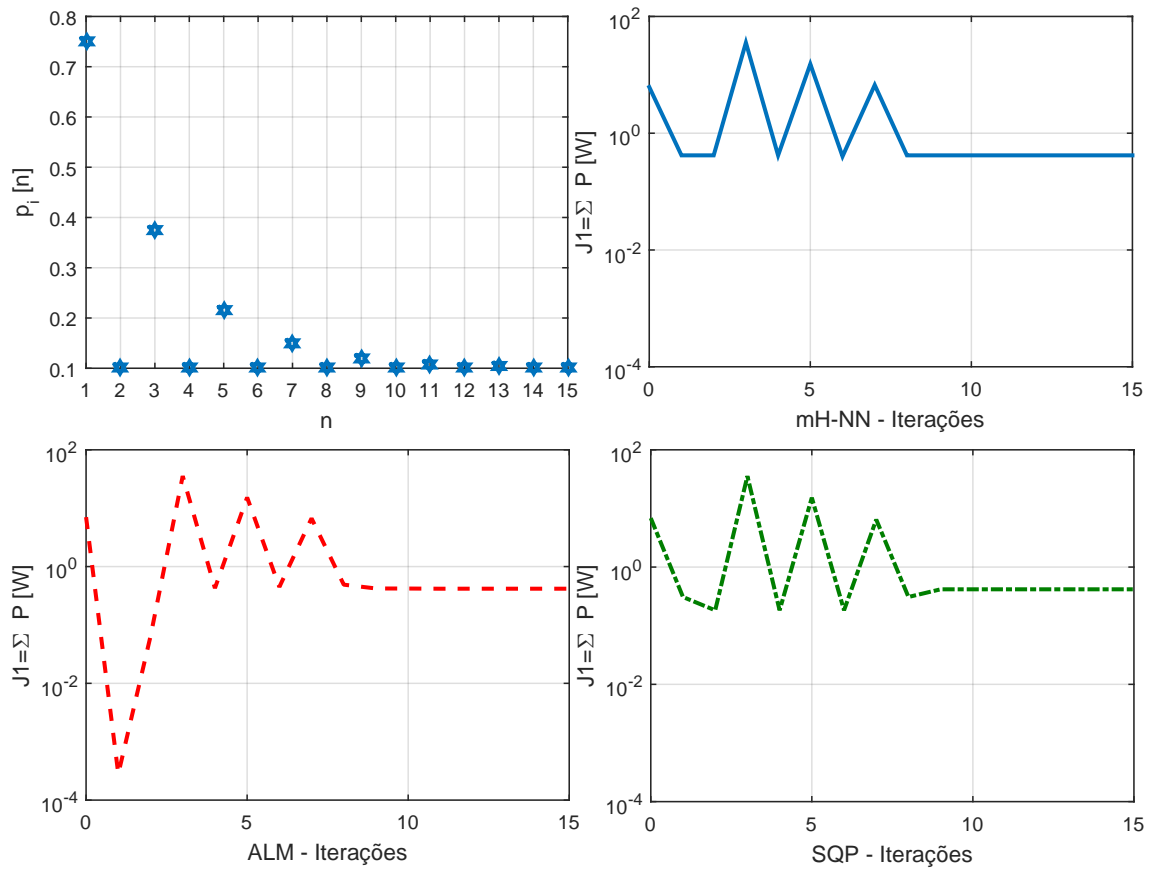


Figura 15: Ilustração da função de perturbação  $p_i[n]$  (59)  $\times$  número de iterações  $n$  com  $p_i^o = 0,1$  W, e respectiva convergência de alocação de potência por ONU considerando uma perturbação inserida em  $2 \leq n \leq 7$  iteração para os métodos mH-NN, SQP e ALM.

Fonte: Autoria própria

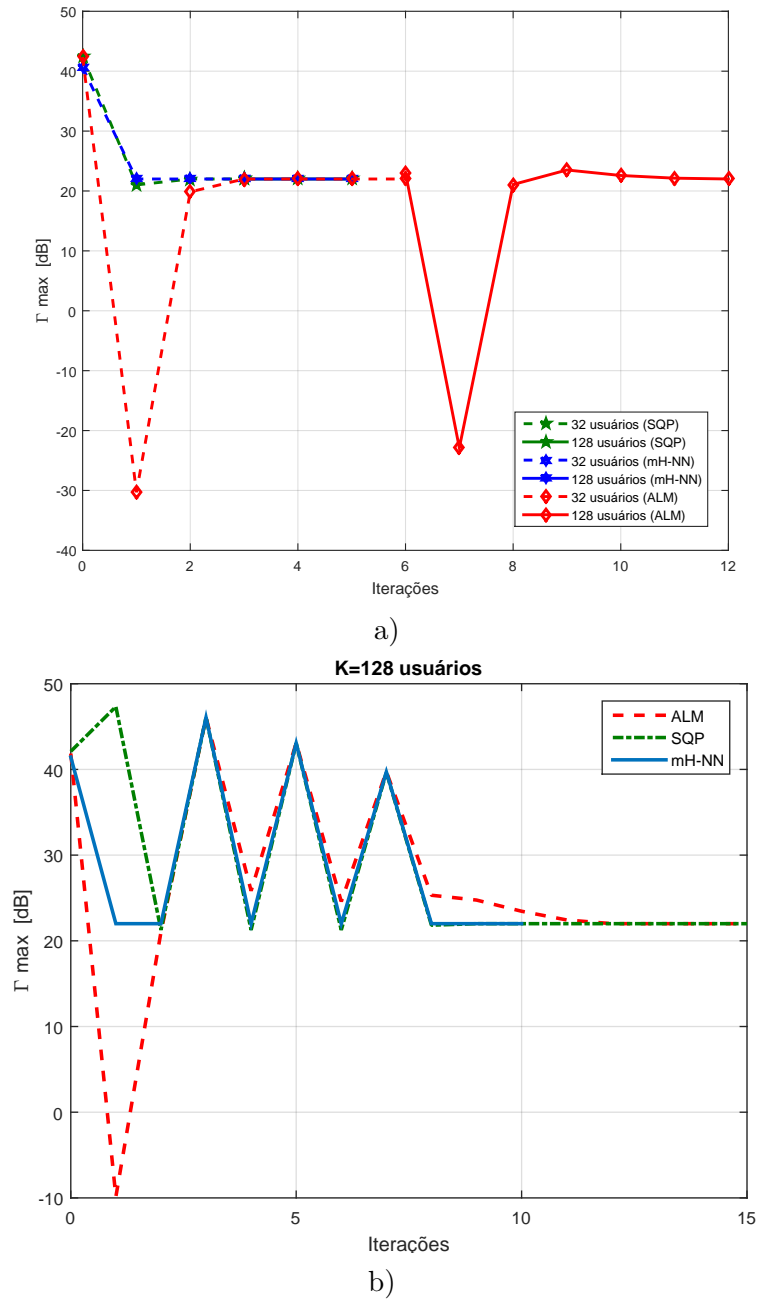


Figura 16:  $\max \Gamma_i$  para: a) sob *on fly* aumentando o número de usuários em 400%; b) considerando uma inserção de perturbação em  $2 \leq n \leq 7$  iteração.

Fonte: Autoria própria

### 3.5 CONCLUSÕES DO CAPÍTULO

Neste capítulo, foi demonstrado que as metodologias estudadas baseadas nos métodos de programação não lineares e redes neurais artificiais são adequadas para solucionar o problema de alocação mínima de potência em redes ópticas OCDMA operando sob diferentes cenários de carregamento do sistema. Destacamos que a proposta de rede mH-NN se mostrou uma alternativa eficaz para resolver o problema de alocação de potência em redes OCDMA, quando comparada aos métodos clássicos de programação devido ao seu baixo custo computacional, enquanto sua simplicidade de implementação não requer treinamento prévio.

É importante notar também que a rede mH-NN geralmente consome muitas iterações para alcançar a convergência, porque usa a direção oposta ao gradiente para otimizar a função objetivo na Etapa III do Algoritmo 1. Além disso, no problema (23), a direção oposta do gradiente se mostrou uma boa opção, uma vez que a função é linear, o que justifica o fato de que o método consumiu poucas iterações para obter convergência.

Enquanto o método SQP aproveita a simplicidade da função objetivo para a construção de subproblemas mais simples, por outro lado, o ALM minimiza a função Lagrangiana aumentada na caixa  $p_{\min} \leq p_i \leq p_{\max}$ , que não é simplificado devido às características da função objetivo. Desta forma, entre os métodos de PNL avaliados, deve-se esperar um melhor desempenho do método SQP em relação ao ALM na determinação da solução do problema de alocação de potência em redes OCDMA.

#### 4 ESTRATÉGIAS PARA A ALOCAÇÃO EFICIENTE DE POTÊNCIA: MAXIMIZAÇÃO DA EFICIÊNCIA ENERGÉTICA

Neste capítulo, serão abordados quatro métodos promissores de programação não linear para a resolução do problema EE-OCDMA apresentado no Capítulo 2, Seção 2.2. Os valores do parâmetro OCDMA implementados, como taxa de bits, ordem de modulação, número de usuários, faixa de transmissão entre outras características foram apresentados na Tabela 1. Mais detalhes podem ser obtidos em (DURAND; ABRAO, 2017), (WONG, 2012).

Além disso, análises numéricas relativas à eficiência energética, convergência e complexidade de algoritmos foram desenvolvidas considerando as quatro abordagens de otimização, isto é, o método de Dinkelbach, o método Lagrangiano aumentado, a programação quadrática sequencial e a técnica de Majoração-minimização, aplicadas para resolver a otimização de EE em redes OCDMA.

O problema de maximização da eficiência energética em redes OCDMA é descrito genericamente por:

$$\max_{\mathbf{p}} J_2(\mathbf{p}) = \frac{S}{P_T} = \frac{\sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i)}{\sum_{i=1}^K p_i + P_c} \quad \left[ \frac{\text{bit}}{\text{Joule}} \right]$$

$$(C.1) \quad p_{\min} \leq p_i \leq p_{\max} \quad (60)$$

$$(C.2) \quad \gamma_i \geq \gamma_i^*, \forall i$$

$$(C.3) \quad r_i \geq r_{i,\min}^{\text{serv}}$$

sendo a SINR para o  $i$ -ésimo usuário dada por

$$\gamma_i = \frac{F_i p_i G_{ii}}{\sum_{j \neq i}^K p_j G_{ij} + \sigma^2}. \quad (61)$$

O vetor gradiente e a matriz Hessiana da função objetivo do problema (60) são

dados respectivamente por:

$$\nabla J_2(\mathbf{p}) = \begin{pmatrix} \frac{\partial J_2(\mathbf{p})}{\partial p_1} \\ \frac{\partial J_2(\mathbf{p})}{\partial p_2} \\ \vdots \\ \frac{\partial J_2(\mathbf{p})}{\partial p_K} \end{pmatrix},$$

$$\nabla^2 J_2(\mathbf{p}) = \begin{bmatrix} \frac{\partial^2 J_2(\mathbf{p})}{\partial p_1^2} & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_1 \partial p_2} & \cdots & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_1 \partial p_K} \\ \frac{\partial^2 J_2(\mathbf{p})}{\partial p_2 \partial p_1} & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_2^2} & \cdots & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_2 \partial p_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 J_2(\mathbf{p})}{\partial p_K \partial p_1} & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_K \partial p_2} & \cdots & \frac{\partial^2 J_2(\mathbf{p})}{\partial p_K^2} \end{bmatrix},$$

cada derivada parcial pode ser calculada da seguinte maneira:

$$\frac{\partial J_2(\mathbf{p})}{\partial p_k} = \frac{\sum_{i=1}^K \left\{ \frac{w_i}{m_i} \left[ \iota \log_2(1 + \theta_i \gamma_i) - \frac{\theta_i \frac{\partial \gamma_i}{\partial p_k}}{1 + \theta_i \gamma_i} \left( \iota \sum_{j=1}^K p_j + P_C \right) \right] \right\}}{\left( \iota \sum_i p_i + P_C \right)^2},$$

$$\nabla \gamma_i(\mathbf{p}) = \begin{pmatrix} \frac{\partial \gamma_i(\mathbf{p})}{\partial p_1} \\ \frac{\partial \gamma_i(\mathbf{p})}{\partial p_2} \\ \vdots \\ \frac{\partial \gamma_i(\mathbf{p})}{\partial p_K} \end{pmatrix}, \quad \frac{\partial \gamma_i}{\partial p_k} = \begin{cases} -\frac{F_i p_i G_{ii}}{\left( \sum_{i \neq j}^K p_j G_{ij} + \sigma^2 \right)^2}, & i \neq k \\ \frac{F_i G_{ii}}{\sum_{i \neq j}^K p_j G_{ij} + \sigma^2}, & i = k \end{cases}$$

e

$$\frac{\partial^2 J_2(\mathbf{p})}{\partial p_l \partial p_k} = \frac{\partial}{\partial p_l} \left[ \frac{\partial J_2(\mathbf{p})}{\partial p_k} \right]$$

$$= \frac{\sum_{i=1}^K \left\{ \frac{w_i}{m_i} \left[ \frac{\theta_i \left[ \frac{\partial^2 \gamma_i}{\partial p_l \partial p_k} (1 + \theta_i \gamma_i) - \theta_i \left( \frac{\partial \gamma_i}{\partial p_k} \right)^2 \right]}{(1 + \theta_i \gamma_i)^2} (\Phi(\mathbf{p}))^3 \right] \right\}}{[\Phi(\mathbf{p})]^4}, - 2\iota \Psi(\mathbf{p}) \Phi(\mathbf{p})$$

$$\Psi(\mathbf{p}) = \sum_{i=1}^K \left\{ \frac{w_i}{m_i} \left[ -\iota \log_2(1 + \theta_i \gamma_i) + \frac{\theta_i \frac{\partial \gamma_i}{\partial p_k}}{1 + \theta_i \gamma_i} \Phi(\mathbf{p}) \right] \right\}$$

$$\Phi(\mathbf{p}) = \iota \sum_{j=1}^K p_j + P_C,$$

e



$$\frac{\partial^2 \gamma_i}{\partial p_l \partial p_k} = \begin{cases} -\frac{2F_i p_i G_{ii} p_l G_{ll}}{(\sum_{i \neq j}^K p_j G_{ij} + \sigma^2)^3}, & i \neq k, i \neq l \\ \frac{F_i G_{ii} [(\sum_{i \neq j}^K p_j G_{ij} + \sigma^2)^2 - p_l G_{ll}]}{\sum_{i \neq j}^K p_j G_{ij} + \sigma^2}, & i \neq k, i = l \\ -\frac{F_i G_{ii} p_l G_{ll}}{(\sum_{i \neq j}^K p_j G_{ij} + \sigma^2)^2}, & i = k \end{cases} .$$

A função objetivo a ser otimizada no problema EE em (60) pode ser classificada como um problema fracional não linear (DINKELBACH, 1967), (SCHAIBLE, 1976). Esta função é a razão entre duas outras funções, que geralmente resultam em programas de otimização fracionários quase côncavos. O numerador de (60) é côncavo em relação às variáveis  $p_i$ , já que é a soma não-negativa de funções côncavas. O denominador é afim, isto é, convexo e côncavo (linear) em relação à variável potência  $p_i$ . Problemas em que a função do numerador é côncava e o denominador é convexa são chamados programas fracionários quase-côncavos (SCHAIBLE; IBARAKI, 1983).

Problemas fracionários côncavos compartilham propriedades importantes com programas côncavos-convexos (não-fracionários) que contribuem para a determinação da solução. Existe apenas um ótimo local na função de custo, e este ideal é também global. Portanto, a solução das condições de optimalidade de Karush-Kuhn-Tucker é máxima se as funções de numerador e denominador forem diferenciáveis no conjunto aberto. Essas características motivam o uso de métodos de PNL na determinação da solução do problema EE.

#### 4.1 MÉTODOS DE PROGRAMAÇÃO NÃO LINEAR

Quatro métodos promissores de programação não linear (DK, SQP, ALM e MaMi) são analisados nesta seção, cujo objetivo é resolver o problema de maximização da eficiência energética em sistemas ópticos CDMA (EE-OCDMA). Tais métodos serão aplicados em (60).

##### 4.1.1 MÉTODO DINKELBACH

É possível resolver programas fracionários côncavos através de ferramentas normalmente usadas para resolver programas côncavos-convexos. Uma maneira amplamente utilizada para resolver programas fracionários é resolver um programa paramétrico equivalente, que geralmente é mais interessante do que resolver o problema original. Tal técnica é denominada método de Dinkelbach, o qual é implementado no procedimento de *loop*

externo iterativo.

O método iterativo de Dinkelbach (DINKELBACH, 1967), (SCHAIBLE, 1976) resolve o problema EE quase-côncavos em uma forma côncava parametrizada. Como o problema (60) é um problema fracionário côncavo-convexo, ele pode ser expresso como:

$$\max_{\mathbf{p} \in \varphi} J_2(\mathbf{p}) = \frac{S(\mathbf{p})}{U(\mathbf{p})} = \frac{\sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i)}{\iota \sum_i^K p_i + P_c} \quad (62)$$

sendo  $\varphi = \{\mathbf{p} \in \mathbb{R}^K | \text{C.1, C.2 e C.3 são satisfeitas}\}$  um conjunto compacto e conectado e sempre  $U(\mathbf{p}) > 0$ . O programa fracionário original acima pode ser associado ao seguinte programa paramétrico côncavo (SCHAIBLE, 1976):

$$\max_{\mathbf{p} \in \varphi} F(J_2) = S(\mathbf{p}) - J_2 U(\mathbf{p}) \quad (63)$$

$J_2 \in \mathbb{R}$  é tratado como um parâmetro. Além disso, sem perda de generalidade, definimos a máxima eficiência energética  $J_2^*$  do sistema considerado como:

$$J_2^* = \frac{S(\mathbf{p}^*)}{U(\mathbf{p}^*)} = \max_{\mathbf{p} \in \varphi} \frac{S(\mathbf{p}^*)}{U(\mathbf{p}^*)}. \quad (64)$$

Um pseudocódigo para o método de Dinkelbach é descrito no Algoritmo 4.

<b>Algoritmo 4: DK-EE – Método de Dinkelbach para EE-OCDMA</b>
<ol style="list-style-type: none"> <li>1 Entrada: <math>J_2^0</math> satisfazendo <math>F(J_2^0) \geq 0</math>; tolerância <math>\zeta</math>;</li> <li>2 Inicialize: <math>n \leftarrow 0</math>;</li> <li>3 <b>repita</b></li> <li>4     Obter <math>\mathbf{p}^*</math> solução de <math>\max_{\mathbf{p} \in \varphi} F(J_2^n) = S(\mathbf{p}) - J_2^n U(\mathbf{p})</math>;</li> <li>5     <math>J_2^{n+1} \leftarrow \frac{S(\mathbf{p}^*)}{U(\mathbf{p}^*)}</math>;</li> <li>6     <math>n \leftarrow n + 1</math></li> <li>7 <b>até</b> <math> F(J_{2n})  \leq \zeta</math>;</li> <li>8 Saída: <math>J_2^n; \mathbf{p}_n</math>.</li> </ol>

Na sequência, apresentamos a técnica de programação convexa disciplinada que, neste trabalho, foi utilizada para resolver o subproblema do método DK.

#### 4.1.1.1 PROGRAMAÇÃO CONVEXA DISCIPLINADA

Em 2006, a programação convexa disciplinada (CvX – *Disciplined Convex Programming*) foi apresentada por Michael Grant, Stephen Boyd e implementada em Matlab® sob o nome de CvX, tornando a programação convexa uma importante opção para resolver problemas de otimização. O CvX (BOYD; VANDENBERGHE, 2004) é um sistema de

modelagem de software desenvolvido na plataforma Matlab para a construção e solução de problemas de otimização através da programação convexa disciplinada. Por ser implementado no Matlab e utilizar suas funções e comandos comuns, o CvX se transforma em uma linguagem de programação propício à modelagem de problemas de otimização, facilitando a manipulação dos resultados obtidos na solução.

Antes de descrever o problema de otimização no CvX, deve-se garantir se ele é convexo, já que o CvX não deve ser usado para verificação de convexidade: existem problemas de otimização convexa que não podem ser resolvidos pelo CvX, a menos que sejam traduzidos de forma equivalente compatível com as regras da programação convexa disciplinada. Por outro lado, se o CvX resolver, então este é um problema de otimização convexa. Também deve ficar claro que é improvável que o CvX funcione eficientemente se o número de variáveis a serem resolvidas for muito grande, da ordem de milhares. Neste caso, é aconselhável desenvolver um *solver* específico para obter eficiência.

#### 4.1.2 MÉTODO DE PROGRAMAÇÃO QUADRÁTICA SEQUENCIAL

O método de programação quadrática sequencial é baseado em gradientes e consiste na aproximação sequencial do problema da PNL como um problema de programação quadrática. Ao contrário de outros métodos, que tentam converter o problema em uma sequência de subproblemas de otimização irrestrita, o SQP tenta resolvê-lo de forma iterativa. A solução em cada etapa é obtida pela solução de uma aproximação não linear, no nosso caso uma aproximação do problema (60), onde  $J_2(\mathbf{p})$  é substituído por uma aproximação quadrática da função objetivo, e as restrições de desigualdade não-lineares são substituídas por aproximações lineares.

A principal ideia na abordagem de otimização SQP é a formulação de um subproblema de programação quadrática baseada em uma aproximação quadrática da função Lagrangiana:

$$\mathcal{L}(\mathbf{p}, \boldsymbol{\mu}) = J_2(\mathbf{p}) + \sum_{i=1}^K \mu_i [\gamma_i^* - \gamma_i(\mathbf{p})]. \quad (65)$$

Assim, a cada iteração  $k$ , o método SQP resolve o seguinte problema de programação quadrática:

$$\begin{aligned} \max_{\mathbf{d}} \quad & J_2(\mathbf{p}^k) + \nabla J_2(\mathbf{p}^k)^\top \mathbf{d} + \frac{1}{2} \mathbf{d}^\top \nabla^2 \mathcal{L}(\mathbf{p}^k) \mathbf{d} \\ \text{s.t.} \quad & -\nabla \gamma_i(\mathbf{p}^k)^\top \mathbf{d} + \gamma_i^* - \gamma_i(\mathbf{p}^k) \geq 0, \quad i = 1 \dots K, \end{aligned} \quad (66)$$

$\nabla^2 \mathcal{L}(\mathbf{p}^k) = \nabla^2 J_2(\mathbf{p}^k) - \sum_{i=1}^K \mu_i^k \nabla^2 \gamma_i(\mathbf{p}^k)$ , com o objetivo de determinar a melhor direção de busca, denotada por  $\mathbf{d}^k$  (a partir do ponto  $\mathbf{p}^k$ ) como a solução de (66) e associada aos multiplicadores de Lagrange  $\boldsymbol{\mu}^k$  na  $k$ -ésima iteração; em seguida, atualiza o próximo vetor de potência  $\mathbf{p}^{k+1}$  que é obtido projetando  $\mathbf{p}^k + a_k \mathbf{d}^k$  na caixa  $p_{\min} \leq p_i \leq p_{\max}$ .

Como no método de Newton, embora o valor ideal da etapa seja  $a_k = 1$ , os valores de  $a_k \in (0, 1]$  são determinados para garantir as propriedades de convergência gerais do método. Além disso, a matriz  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$  é uma aproximação positiva definitiva para a matriz Hessiana da função Lagrangiana, que pode ser atualizada por qualquer método diferenças finitas de acordo com (NOCEDAL; WRIGHT, 2006).

Assim, usando o método SQP, um problema não linear pode ser resolvido em menos iterações, com complexidade semelhante a um problema quadrático. Uma das razões para isso é que, devido aos limites da região viável, o otimizador pode tomar decisões sobre as direções de busca e o comprimento do passo. O Algoritmo 5 resume o método SQP.

**Algoritmo 5:** SQP-EE – Programação Quadrática Sequencial para EE-OCDMA

- 1 Escolha um ponto inicial  $(\mathbf{p}^0, \boldsymbol{\mu}_0)$  e tolerância  $\zeta > 0$ ;
- 2  $k = 0$ ;
- 3 **repita**
- 4     Avalie  $J_2(\mathbf{p}^k)$ ,  $\nabla J_2(\mathbf{p}^k)$ ,  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$ ,  $\gamma_i(\mathbf{p}^k)$  e  $\nabla \gamma_i(\mathbf{p}^k)$ ;
- 5     Resolva (66) para obter  $\mathbf{d}^k$  e  $\boldsymbol{\mu}^{k+1}$ ;
- 6      $\mathbf{p}^{k+1} \leftarrow \mathcal{P}(\mathbf{p}^k + \mathbf{a}_k \mathbf{d}^k)$  sendo  $\mathcal{P}$  é o operador projeção ortogonal na caixa  $p_{\min} \leq p_i \leq p_{\max}$ ;
- 7      $k \leftarrow k + 1$ ;
- 8 **até**  $\|\mathbf{p}^{k+1} - \mathbf{p}^k\| < \zeta$ ;

### 4.1.3 MÉTODO DO LAGRANGIANO AUMENTADO

Considerando o problema de programação não linear definido em (60), considere  $\Omega$  um subconjunto simples de  $\mathbb{R}^K$  definido como:

$$\Omega = \{\mathbf{p} \in \mathbb{R}^K \mid p_{\min} \leq p_i \leq p_{\max}\}.$$

Assumimos que as funções  $J_2(\mathbf{p}) : \mathbb{R}^K \rightarrow \mathbb{R}$ ,  $\gamma_i(\mathbf{p}) : \mathbb{R}^K \rightarrow \mathbb{R}^K$  possuem primeiras derivadas contínuas em  $\mathbb{R}^K$ .

Para nosso problema de PNL (60), dado um parâmetro de penalidade  $\rho > 0$ , e aproximações  $\mu_i \geq 0$  para o multiplicador de Lagrange, a função Lagrangiano aumentada para o problema de otimização EE-OCDMA pode ser definida como:

$$\mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu}) = J_2(\mathbf{p}) + \frac{\rho}{2} \sum_{i=1}^K \left[ [\gamma_i^* - \gamma_i(\mathbf{p})]^+ + \frac{\mu_i}{\rho} \right]^2 \quad (67)$$

$$[\alpha]^+ = \max[0, \alpha].$$

Os principais passos do ALM:

**Passo 1** Inicialização: dados os multiplicadores iniciais  $\boldsymbol{\mu}$  e valores de penalidade  $\rho$ ;

**Passo 2** Resolva o problema Lagrangiano aumentado associado,  $\max_{\mathbf{p} \in \Omega} \mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu})$

**Passo 3** Decida se o ponto obtido no Passo 2 pode ser aceito como solução do problema original, caso contrário, vá para a próxima etapa.

**Passo 4** De acordo com os resultados das etapas anteriores, atualize os multiplicadores e o parâmetro de penalidade,

Atualiza os multiplicadores de Lagrange:

$$\mu_i^{k+1} = \max\{0, \mu_i^k + \rho_k(\gamma_i^* - \gamma_i(p^k))\}, \quad i = 1, \dots, m \quad \text{e} \quad \mu_i^{k+1} \in [0, \mu_{\max}].$$

Atualize os parâmetros de penalidade:

$$V_i^k = \max \left\{ \gamma_i^* - \gamma_i(p^k), -\frac{\mu_i^k}{\rho_k} \right\}.$$

$$\text{Se } \|V^k\|_\infty \leq \tau \|V^{k-1}\|_\infty \quad \text{então} \quad \rho_{k+1} = \rho_k.$$

$$\text{Caso contrário} \quad \rho_{k+1} = \nu \cdot \rho_k, \quad \text{sendo } \nu > 1.$$

Voltar para o Passo 1.

Como descrito na Seção 2.3, no ALM, o parâmetro de penalidade é colocado para ser pequeno nas primeiras iterações externas. Assim, nas primeiras iterações o método tende a privilegiar a otimização de  $J_2$ . A condição apresentada em (68), (73) e (100) implica que  $\mathbf{p}^k$  é uma solução aproximada de  $\max_{\mathbf{p} \in \Omega} \mathcal{A}(\mathbf{p}, \mu^k)$ .

O pseudocódigo descrito no Algoritmo 6 é uma versão simplificada do método Lagrangiano aumentado para o problema EE. Para determinar  $\mathbf{p}^k$  aplicamos a função de otimização *fmincon* do *Optimization Toolbox* do Matlab. Uma análise a respeito da convergência do ALM pode ser encontrado em (BIRGIN et al., 2011), (ANDREANI et al., 2007a).

**Algoritmo 6:** ALM-EE – Método do Lagrangiano aumentado para o EE-OCDMA

1 Parâmetros de Entrada:  $\mu_{\max} > 0$ ,  $\mu_i^1 \in [0, \mu_{\max}]$ ,  $\forall i = 1, \dots, m$ ,  
 $\zeta > 0, \{\varepsilon_k\} \subset \mathbb{R}_+$ , sendo  $\varepsilon_k$  é um parâmetro de tolerância de modo que  
 $\lim_{k \rightarrow \infty} \varepsilon_k = 0$ ;  
2 Faça  $k \leftarrow 1$ ;  
3 **repita**  
4     Calcular com a função *fmincon* do Matlab  $\mathbf{p}^k \in \mathbb{R}^K$  satisfazendo

$$\left\| \mathcal{P}(\mathbf{p}^k - \nabla \mathcal{A}(\mathbf{p}^k, \boldsymbol{\mu}^k)) - \mathbf{p}^k \right\| \leq \varepsilon_k, \quad (68)$$

sendo  $\mathcal{P}$  é o operador projeção na caixa  $p_{\min} \leq p_i \leq p_{\max}$ . Atualize os multiplicadores de Lagrange e o parâmetro de penalidade;  
5      $k \leftarrow k + 1$   
6 **até**  $\|\mathbf{p}^{k+1} - \mathbf{p}^k\| < \zeta$ ;

#### 4.1.4 MÉTODO DE MAJORAÇÃO-MINIMIZAÇÃO

Majoração-Minimização ou Minimização-Majoração (MiMa) é uma técnica iterativa capaz de lidar com a não-convexidade do problema de otimização, para obter um problema mais simples em cada iteração (SUN et al., 2017), (STOICA; SELEN, 2004), (NAGHSH et al., 2004). O método MaMi é uma técnica iterativa usada para obter uma solução para o problema geral de maximização:

$$\begin{aligned} & \max_{\mathbf{p}} \quad f(\mathbf{p}) \\ & \text{s. t.} \quad \mathbf{g}(\mathbf{p}) \leq 0 \end{aligned}$$

$f(\cdot)$  e  $\mathbf{g}(\cdot)$  podem ser funções não convexas; no problema de otimização EE,  $f = J_2(\mathbf{p})$  e  $g_i = \gamma^* - \gamma_i(\mathbf{p})$ .

O método MaMi pode ser resumido em dois passos:

---

**Passo 1 (Minoração):** Encontrando um  $\tilde{q}^{(k)}(\mathbf{p})$  função estritamente côncava de tal

forma que a sua maximização é mais simples do que o original  $f(\mathbf{p})$  e  $\tilde{q}^{(k)}(\mathbf{p})$  minoriza  $f(\mathbf{p})$ , na  $k$ -ésima iteração devem ser satisfeitas simultaneamente:

$$\tilde{q}^{(k)}(\mathbf{p}) \leq f(\mathbf{p}) \quad \forall \mathbf{p} \quad \text{e} \quad \tilde{q}^{(k)}(\mathbf{p}^{(k-1)}) = f(\mathbf{p}^{(k-1)})$$


com  $\mathbf{p}^{(k-1)}$  sendo o valor de  $\mathbf{p}$  na  $(k-1)$ -ésima iteração.

**Passo 2 (Maximização):** Resolvendo o problema de otimização:

$$\begin{aligned} \max_{\mathbf{p}} \quad & \tilde{q}^{(k)}(\mathbf{p}) \\ \text{s. t.} \quad & \mathbf{g}(\mathbf{p}) \leq 0 \end{aligned}$$

para obter  $\mathbf{p}^{(k)}$ . A Figura 17 ilustra estes dois passos.

A  $k$ -ésima iteração do algoritmo MaMi consiste em duas etapas, resumidas na sequência, enquanto um pseudocódigo para o método MaMi aplicado ao problema EE é apresentado no Algoritmo 7.



**Figura 17:** Uma ilustração gráfica dos dois passos da técnica MaMi.

**Fonte:** Autoria própria

No Algoritmo 7 não incluímos a restrição (C.3) visto que a mesma pode ser mapeado pela restrição (C.2) como detalhado na seção 4.2.

**Algoritmo 7:** MaMi-EE – Majoração-Minimização para EE-OCDMA maximização

**1** Escolha um ponto inicial  $\mathbf{p}^0$  e tolerância  $\zeta > 0$ ;  
**2**  $k = 0$ ;  
**3 repita**  
**4** Defina  $\tilde{q}^{(k)}(\mathbf{p})$ , de modo que  $\tilde{q}^{(k)}(\mathbf{p})$  minorize  $J_2(\mathbf{p})$ ;  
**5** Obtém-se  $\mathbf{p}^{k+1}$  como uma solução do problema:
 
$$\begin{aligned} \max_{\mathbf{p}} \quad & \tilde{q}^{(k)}(\mathbf{p}) \\ \text{s. t.} \quad & \gamma_i^* - \gamma_i(\mathbf{p}) \leq 0 \\ & p_{\min} \leq p_i \leq p_{\max} \\ & r_{i,\min}^{\text{serv}} - r_i \leq 0. \end{aligned}$$

**6 até**  $k \leftarrow k + 1$   
 $\|\mathbf{p}^{k+1} - \mathbf{p}^k\| < \zeta$ ;

#### 4.2 ASPECTOS DE IMPLEMENTAÇÃO DOS MÉTODOS DE PNL NA SOLUÇÃO DO PROBLEMA EE-OCDMA

Nesta seção são discutidos os aspectos relevantes para a implementação dos quatro métodos de PNL considerados na Seção 4.1.

Implementação: **DK-CvX**. O método de Dinkelbach foi implementado através de ferramentas CvX (BOYD; VANDENBERGHE, 2004), baseado na implementação de (MARQUES et al., 2016), com as seguintes adaptações:

- ◇ O CvX não aceita uma função do tipo  $\log(1 + Ap_i)$ , então esta foi implementada como  $\log(p_i(1/p_i^k + A))$ , sendo  $p_i^k$  é uma aproximação para  $p_i$ , desta forma a função objetivo fica mais próxima do valor exato considerando  $p_i^k \rightarrow p_i$ .
- ◇ Como no código de (MARQUES et al., 2016), as restrições originais não são aceitas pelo CvX na forma original  $\gamma \geq \gamma^*$ , assim foi utilizado o inverso,  $\frac{1}{\gamma} \leq \frac{1}{\gamma^*}$  que é equivalente a restrição original porém é aceita pelo CvX.

Implementação: **SQP**. No método SQP foi utilizada a função de otimização `fmincon` do *Optimization Toolbox* do Matlab com a opção de algoritmo sendo ‘SQP’, que é uma implementação do método de programação quadrática sequencial apresentado no Algoritmo 5.



Implementação: ALM. O algoritmo ALM foi inicializado com os multiplicadores sendo zeros e o parâmetro de penalidade,  $\rho = 10$ , para calcular  $\max_{\mathbf{p} \in \Omega} \mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu})$  foi utilizada a função de otimização *fmincon* do *Optimization Toolbox* do Matlab.

Implementação: MaMi. Na técnica de minimização de majoração, considerou-se uma função quadrática obtida da expansão em série de Taylor da função objetivo de EE (60) até ordem 2. Para o cálculo das derivadas de primeira e segunda ordem, foram aplicadas diferenças finitas. Em relação à restrição (C.2) em (60), como  $\gamma^*$  considerado é constante, reescrevemos a restrição de QoS do problema como uma restrição linear:

$$\begin{aligned} \gamma &\geq \gamma^* \\ \frac{F p_i G_{ii}}{\sum_{i \neq j}^K p_j G_{ij} + \sigma^2} &\geq \gamma^* \\ F p_i G_{ii} &\geq \gamma^* \left( \sum_{i \neq j}^K p_j G_{ij} \right) + \gamma^* \sigma^2 \end{aligned}$$

que, reescrita em notação matricial, tem a seguinte forma:

$$\begin{aligned} F \begin{pmatrix} G_{11} & 0 & \dots & 0 \\ 0 & G_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & G_{KK} \end{pmatrix} \mathbf{p} &\geq \gamma^* \overline{\mathbf{G}} \mathbf{p} + \gamma^* \sigma^2 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \\ \left[ F \begin{pmatrix} G_{11} & 0 & \dots & 0 \\ 0 & G_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & G_{KK} \end{pmatrix} - \gamma^* \overline{\mathbf{G}} \right] \mathbf{p} &\geq \gamma^* \sigma^2 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \\ \left[ -F \begin{pmatrix} G_{11} & 0 & \dots & 0 \\ 0 & G_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & G_{KK} \end{pmatrix} + \gamma^* \overline{\mathbf{G}} \right] \mathbf{p} &\leq -\gamma^* \sigma^2 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \end{aligned}$$

$$[-F \mathbf{G}_{ii}^2 + \gamma^* \overline{\mathbf{G}}] \mathbf{p} \leq -\sigma^2 \gamma^*,$$

$$\overline{\mathbf{G}} = \begin{cases} G_{ij}, & i \neq j; \\ 0, & j = i. \end{cases}$$

Desta forma, foi possível aplicar o *Toolbox Quadprog* do Matlab para resolver o subproblema em cada iteração do método MaMi que, neste caso, consistiu na resolução de um problema quadrático.

Para todos os métodos, consideramos que a restrição (C.3) do problema original (60) pode ser mapeada em (C.2). Na verdade, da equação de Shannon resulta:

$$r_i = w_i \log_2(1 + \theta_i \gamma_i) \geq r_{\min} \quad (69)$$

$$\begin{aligned} \log_2(1 + \theta_i \gamma_i) &\geq \frac{r_{\min}}{w_i} \\ 1 + \theta_i \gamma_i &\geq 2^{\frac{r_{\min}}{w_i}} \\ \theta_i \gamma_i &\geq 2^{\frac{r_{\min}}{w_i}} - 1 \\ \gamma_i &\geq \frac{2^{\frac{r_{\min}}{w_i}} - 1}{\theta_i}. \end{aligned}$$

Na rede OCDMA, a BER e a SINR são relacionados pela Equação (69) para diferentes classes de tráfego/usuários; portanto, o processo de otimização do SINR baseado na definição de potência transmitida otimizada impacta diretamente no desempenho do sistema. Assim sendo, não é necessário implementar a restrição (C.3) diretamente, em vez disso, a taxa mínima por classe de serviço na restrição (C.3) é mapeada em um mínimo de SINR, na restrição (C.2).

Consideramos o mesmo critério de parada para todos os algoritmos, se após a iteração externa  $k$  tivermos  $\mathbf{p}^k$  viável e satisfeita a desigualdade  $\|\mathbf{p}^k - \mathbf{p}^{k-1}\| < 10^{-6}$ , o algoritmo interrompe a execução, declarando a convergência. Por definição, os métodos SQP e ALM calculam as aproximações para os multiplicadores, tal cálculo é acoplado aos métodos DK e MaMi; desta forma, a optimalidade  $\Theta$  é determinada pela norma (70):

$$\Theta = \|\mathcal{P}(\mathbf{p}^k - \nabla \mathcal{L}(\mathbf{p}^k, \boldsymbol{\mu}^k)) - \mathbf{p}^k\| = \|\mathcal{P}(\mathbf{p}^k - \nabla J_2(\mathbf{p}^k) - \sum_{i=1}^K \mu_i^k \nabla \gamma_i(\mathbf{p}^k)) - \mathbf{p}^k\| \rightarrow 0 \quad (70)$$

no ponto  $\mathbf{p}^k$  com a respectiva aproximação dos multiplicadores. Os quatro métodos de PNL foram avaliados em dois cenários diferentes de operação OCDMA baseados em QoS com um número crescente de nós ópticos: a) uma classe de serviço com uma restrição de taxa mínima; b) três classes de serviços com diferentes restrições de QoS e taxa mínima. Para as métricas de desempenho foram avaliadas optimalidade, convergência e complexidade.

Os testes foram realizados no MatLab 8.0, Windows 10 computador Home Single Language, versão 1703, CPU Intel Core i7-7700HQ a 2.80GHz, 16.00GB de RAM, sistema operacional com 64 bits. Os principais valores dos parâmetros do sistema são resumidos na Tabela 8. A distribuição BER para as três classes diferentes é ordenada como  $BER_3 < BER_2 < BER_1$  com pelo menos uma ordem de grandeza entre duas classes consecutivas.

### 4.3 RESULTADOS NUMÉRICOS

Nesta seção, são apresentados resultados dos testes numéricos que levam em consideração topologias de redes ópticas realísticas baseadas em códigos MLEWHPC 2-D, os quais suportam serviços operando sob diferentes classes de QoS e distintas taxas de bits alcançáveis descritas na Seção 2.3. A arquitetura de rede OCDMA usada é similar à dos trabalhos (WONG, 2012) e (DURAND; ABRAO, 2017). As implementações são completamente distribuídas e nenhum treinamento é necessário.

Apresentamos na Tabela 8 os valores dos parâmetros adotados para a rede. A SINR alvo de 20dB foi escolhida para atingir uma transmissão adequada na rede de taxa única (Cenário A), o que resulta em um BER menor que o limite “livre de erros” ( $\sim 10^{-12}$ ), enquanto a transmissão na rede multi-taxa (Cenário B) é estabelecida para atingir BER de  $10^{-12}$ ,  $10^{-11}$  e  $10^{-10}$  para a CLASSE 3, CLASSE 2 e CLASSE 1, respectivamente.

**Tabela 8: Valores de parâmetros adotados.**

Valores de Parâmetros	
Ordem de modulação	$M = 2$
Ineficiência do Transponder	$\iota = 2,7\text{W/Gbps}$
Ruído Branco std	$\sigma = 0,032\text{dB}$
Constante de Planck	$h = 6,63 \times 10^{-34} \text{ J/Hz}$
Período de Chip	$T_c = 9 \text{ ps}$
alcance do comprimento	de link $[4, 100] \text{ km}$
Max. potência do laser	$p_{\max} = 20 \text{ dBm}$
Min. potência do laser	$p_{\min} = (p_{\max} - 90) \text{ dBm}$
SINR	$\gamma_i^* = 20\text{dB}$
<b>Cenário A: “serv” = classe única</b>	
Número de usuários	$K \in \{8, 16, 32\}$
Min. taxa de usuários	$r_{\min}^{\text{serv}} > 0$
comprimento da sequência OCDMA	$F_i = \frac{T_b}{T_c} = 121$
Max. BER aceitável	$BER \leq 10^{-12}$
<b>Cenário B: “serv” = {classe 1, classe 2, classe 3}</b>	
Usuários por classe	$K \in \{U^{\text{CLASSE 1}}, U^{\text{CLASSE 2}}, U^{\text{CLASSE 3}}\}$
$U^{\text{CLASSE}} = [8, 16, 32]$	$\{[4; 2; 2], [8; 4; 4], [24; 4; 4]\}$
comprimento da sequência OCDMA	$F_i = \frac{T_b}{T_c} \in \{1331, 121, 11\}$
Min. taxa de usuários por classe	$r_{\min}^{\text{serv1}} = 10 \text{ Mbps}; \quad BER_{\max}^{\text{serv1}} = 10^{-10}$
e respectivo	$r_{\min}^{\text{serv2}} = 100 \text{ Mbps}; \quad BER_{\max}^{\text{serv2}} = 10^{-11}$
Max. BER aceitável	$r_{\min}^{\text{serv3}} = 1000 \text{ Mbps}; \quad BER_{\max}^{\text{serv3}} = 10^{-12}$

#### 4.3.1 OTIMIZAÇÃO DE EE SEM RESTRIÇÃO NO SERVIÇO DE TAXA MÍNIMA $R_{\text{MIN}}^{\text{SERV}}$ (CENÁRIO A)

Para o primeiro cenário, foram aplicados os quatro algoritmos EE-OCDMA para diferentes números de nós, considerando os parâmetros descritos na Tabela 8. Na Tabela 9 apresentamos valores relevantes referentes ao desempenho dos quatro métodos, incluindo o tempo de execução, valor máximo de eficiência energética, número de iterações para convergência e a optimalidade dos quatro algoritmos EE-OCDMA, como definido em (70), e considerando o aumento do número de nós ópticos,  $K \in \{8, 16, 32\}$  usuários.

Todos os métodos convergiram para pontos factíveis. Além disso, a Tabela 9 mostra que os quatro métodos atingem o valor ótimo de potência que maximiza a EE da rede OCDMA operando sob Cenário A. Ademais, pode-se observar o tempo elevado necessário para o método DK atingir a convergência total quando comparado aos outros métodos. Pode-se notar também que o método DK obteve o pior valor para optimalidade e, em contraste, o método MaMi obteve os melhores valores.

A redução das restrições definidas por (C.2) no problema (60) para restrições lineares contribuiu para o bom desempenho neste aspecto do método MaMi, bem como na determinação das melhores soluções a partir do ponto de vista da optimalidade. Devido à simplicidade do algoritmo (comparado ao ALM e SQP), estes resultados indicam que o MaMi provou ser uma alternativa muito promissora para cenários de operação típicos (Cenário A).

A Figura 18 descreve a evolução da convergência de EE para os quatro métodos e diferentes números de nós ópticos operando ainda no Cenário A. De acordo com a Tabela 9, os quatro métodos atingiram a convergência. Em relação ao tempo de convergência, o método DK consumiu muito mais tempo do que os outros métodos. Isso ocorre porque suas iterações internas com CvX têm maior custo computacional. Apesar de o SQP consumir um número maior de iterações, cada uma delas é rápida, fazendo com que o método obtenha um melhor desempenho de complexidade em relação aos outros métodos discutidos. Além disso, o método MaMi no Cenário A demonstrou um desempenho e complexidade adequados, principalmente porque explora de melhor forma as características das restrições ao reescreve-las como lineares. Podemos observar também que as aproximações quadráticas provam ser uma boa opção para o problema de maximização EE-OCDMA.

Finalmente, o ALM é conhecido na literatura por possuir um bom desempenho

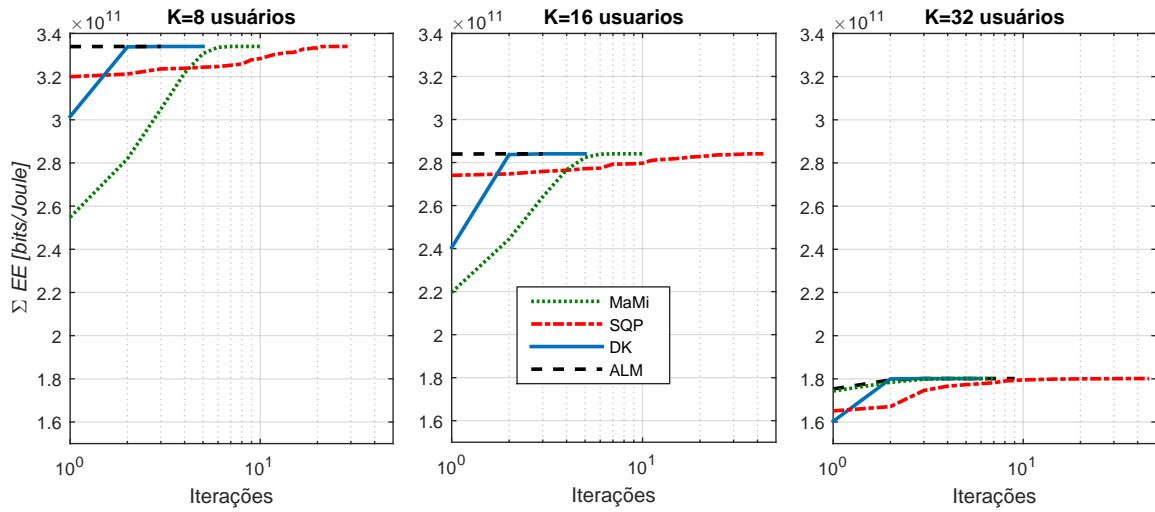
Tabela 9: Tempo de execução, valores de EE atingíveis, número de iterações para convergência e optimalidade para os algoritmos EE-OCDMA, considerando o aumento do número de nós ópticos.

Método	Tempo [s]	$J_2(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	Iter.	Optimalidade
<b>8 usuários</b>				
DK	60,20952	$3,3396 \times 10^{+11}$	5	0,0207
ALM	0,1493061	$3,3396 \times 10^{+11}$	<b>3</b>	0,0071
SQP	<b>0,143147</b>	$3,3396 \times 10^{+11}$	29	$1,812 \times 10^{-5}$
MaMi	0,2998010	$3,3396 \times 10^{+11}$	10	<b><math>1,2307 \times 10^{-8}</math></b>
<b>16 usuários</b>				
DK	221,9435	$2,8404 \times 10^{+11}$	5	0,0718
ALM	0,328204	$2,8404 \times 10^{+11}$	<b>3</b>	0,0071
SQP	<b>0,222652</b>	$2,8404 \times 10^{+11}$	43	$2,787 \times 10^{-4}$
MaMi	0,4152730	$2,8404 \times 10^{+11}$	10	<b><math>2,1018 \times 10^{-8}</math></b>
<b>32 usuários</b>				
DK	$2,2330 \times 10^{+4}$	$1,8012 \times 10^{+11}$	<b>6</b>	0,1010
ALM	2,731484	$1,8012 \times 10^{+11}$	9	0,0543
SQP	<b>0,546597</b>	$1,8012 \times 10^{+11}$	46	$1,366 \times 10^{-5}$
MaMi	1,088544	$1,8012 \times 10^{+11}$	7	<b><math>2,3399 \times 10^{-8}</math></b>

ao tratar problemas de otimização. Aqui, para o (simples) Cenário A, embora o tempo de processamento tenha sido consideravelmente maior que os métodos SQP e MaMi para  $K = 32$  usuários, o ALM alcançou a solução ótima para todas as dimensões (número de usuários,  $K$ ) consideradas. Ademais, o método DK atingiu a convergência para todos os  $K$  usuários considerados, mas necessitou de muito mais tempo que os outros métodos o que faz com que o uso do procedimento DK não seja indicado em redes maiores.

#### 4.3.2 OTIMIZAÇÃO DE EE COM RESTRIÇÃO NO SERVIÇO DE TAXA MÍNIMA, $R_{\text{MIN}}^{\text{SERV}}$ (CENÁRIO B)

O problema considerado é definido para um sistema OCDMA simples, enquanto ele pode ser estendido para analisar o sistema OCDMA em vários níveis em que ONU transmite com potência diferente (BEYRANVAND et al., 2009), (BEYRANVAND et al., 2013), (CHEN et al., 2011a). Considerando os parâmetros descritos anteriormente na Tabela 8 para o Cenário B onde  $\mathcal{C} = 3$  classes de serviço, com  $K = 8, 16$  e  $32$  usuários por classe, respectivamente. O desempenho dos quatro algoritmos EE-OCDMA é comparado em termos de: a) tempo de execução; b) valor máximo de eficiência energética; c) número de iterações; d) factibilidade; e) optimalidade.



**Figura 18: Convergência para o problema EE-OCDMA no Cenário A e considerando diferentes métodos de otimização e número de usuários  $K \in \{8; 16; 32\}$ .**

**Fonte: Autoria própria**

A Figura 19 mostra a convergência global de EE para os métodos de otimização ALM, SQP e MaMi. A Tabela 10 resume os valores de desempenho para os quatro métodos de otimização sob Cenário B. A inclusão dos serviços CLASSE 1, CLASSE 2 e CLASSE 3 no problema de otimização de EE implica que a determinação da solução ótima de EE seja consideravelmente mais difícil. Após a realização dos testes, podemos observar que o método DK não atingiu o valor ótimo em nenhum dos casos. Apenas para  $K = 32$  o método DK chegou perto do valor máximo e ficou 3,76% abaixo do valor ótimo do  $\Sigma EE$ . Os outros métodos mantiveram o bom desempenho alcançado no Cenário A de classe única, em que o método SQP manteve o menor tempo de processamento. Podemos destacar novamente que o método MaMi, apesar de ter um algoritmo simples, aproveitou muito bem a estrutura do problema e, portanto, se comportou de forma similar ao ALM e ao SQP. Os resultados numéricos na Tabela 10 e a Figura 19 indicaram a eficácia dos três métodos ALM, SQP e MaMi em resolver o problema EE-OCDMA também em cenários mais desafiadores em termos de requisitos de QoS, ou seja, taxa mínima por classe e cenários com potência restrita.

Vale ressaltar que, para o Cenário B, as taxas obtidas para as CLASSE 1, CLASSE 2 e CLASSE 3 após a respectiva convergência para os algoritmos ALM-EE, SQP-EE e MaMi-EE são sempre ligeiramente maiores ou iguais à taxa mínima especificada por cada classe

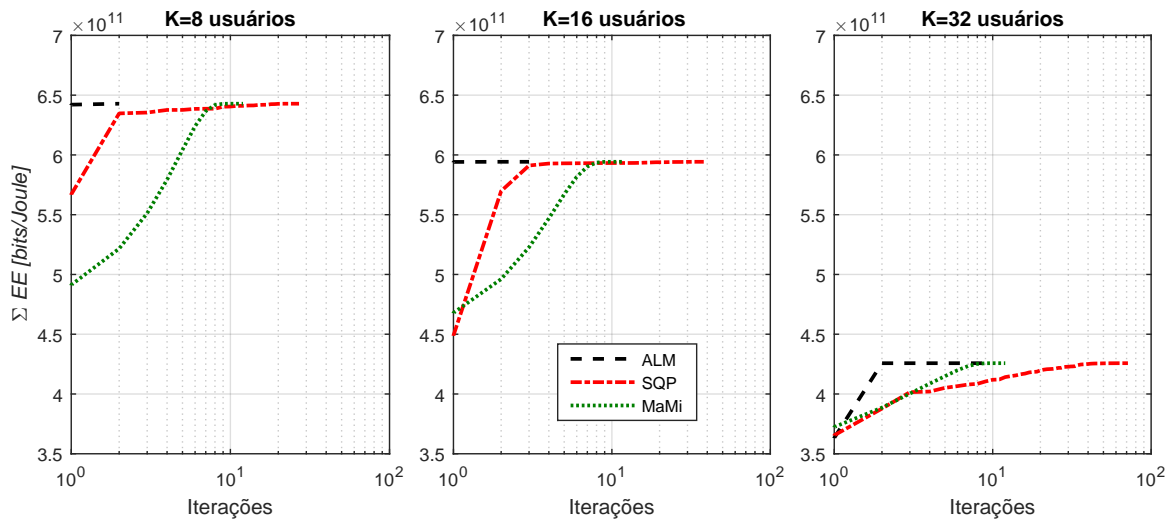


Figura 19: Convergência para EE total das três classes de serviço Classe 1, Classe 2 e Classe 3 e número de usuários  $K \in \{8; 16; 32\}$ .


Fonte: Autoria própria

Tabela 10: Tempo de execução, valor EE atingível, número de iterações para convergência, número de avaliações de funções e optimalidade para os algoritmos EE-OCDMA considerando Três classes de serviços (Cenário B) e número crescente de nós ópticos.

Método	Tempo [s]	$J_2(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	Iter.	FuncCont	Optimalidade
<b>8 usuários. 3 Classes de Serviço</b>					
ALM	0,205664	$7,0236 \times 10^{+11}$	<b>3</b>	546	0,0056
SQP	<b>0,063848</b>	$7,0236 \times 10^{+11}$	20	<b>313</b>	$3,948 \times 10^{-4}$
MaMi	0,177841	$7,0236 \times 10^{+11}$	12	876	<b><math>6,5908 \times 10^{-7}</math></b>
<b>16 usuários. 3 Classes de Serviço</b>					
ALM	0,283374	$6,5394 \times 10^{+11}$	<b>4</b>	922	0,0039
SQP	<b>0,172877</b>	$6,5394 \times 10^{+11}$	37	<b>870</b>	$5,655 \times 10^{-4}$
MaMi	0,512421	$6,5394 \times 10^{+11}$	12	1736	<b><math>2,4711 \times 10^{-6}</math></b>
<b>32 usuários. 3 Classes de Serviço</b>					
ALM	<b>0,415991</b>	$5,6860 \times 10^{+11}$	<b>5</b>	<b>1505</b>	$7,7615 \times 10^{-4}$
SQP	0,453475	$5,6860 \times 10^{+11}$	52	2174	$1,249 \times 10^{-4}$
MaMi	1,521938	$5,6860 \times 10^{+11}$	11	7187	<b><math>4,7478 \times 10^{-7}</math></b>

de serviço. Assim, a rede óptica com  $K = 32$  usuários opera sob a configuração de máxima  $EE$ , enquanto todos os usuários satisfazem suas respectivas QoS por classe.

Podemos ver, a partir da Tabela 10 e a Figura 19, que os métodos de otimização ALM, SQP e MaMi convergiram para pontos de factibilidade e para a solução considerando  $K = 8, 16, 32$  usuários distribuídos em três classes de serviços. Por outro lado, o método DK-CvX não é capaz de obter convergência. Podemos notar uma tendência de um maior número de avaliações de funções (FuncCont) para o método MaMi, como observado na Figura 20. No entanto, vale ressaltar que, neste caso, estamos trabalhando com as restrições linearizadas, o que resulta em um custo computacional mais baixo por avaliação quando comparado à avaliação da restrição original considerada pelos métodos ALM e SQP. Por outro lado, esperávamos um número menor de avaliações do SQP em relação ao ALM, devido às características do método SQP, o que de fato ocorreu para  $K = 8$  e 16 usuários. Entretanto, para  $K = 32$  usuários, o SQP consumiu maior número de avaliação de funções requerendo 52 iterações para obter a convergência, enquanto o ALM precisou de apenas 5 iterações, o que também refletiu em um maior tempo para convergência.



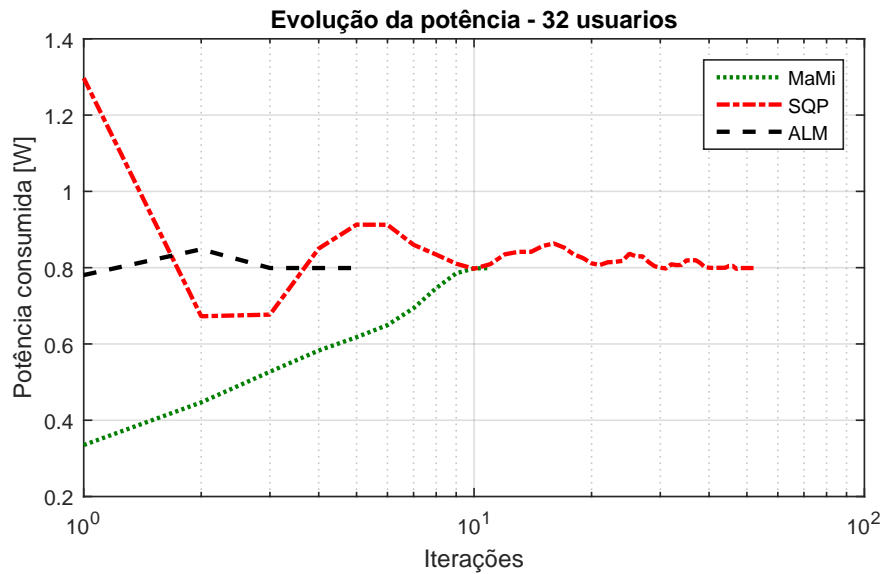
**Figura 20:** Evolução do número total de avaliação de funções dos métodos testados para  $K = [8, 16, 32]$  usuários.

**Fonte:** Autoria própria

Depois de observar o desempenho dos três métodos de otimização não-linear nos Cenários A e B, consideramos o valor total de consumo de potência atingível pelo



Algoritmo 5 após a convergência como referência para análise e evolução do consumo de potência do ALM e MaMi para  $K = 8, 16$  e  $32$  nós ópticos. A Figura 21 ilustra a evolução da somatória das potências ao longo das iterações para os três métodos de programação não linear considerados, sob  $K = 32$  nós ópticos distribuídos em três classes de serviço,  $\{U^{\text{CLASSE 1}}, U^{\text{CLASSE 2}}, U^{\text{CLASSE 3}}\} \equiv [24; 4; 4]$  usuários. Como se pode notar, os três métodos convergem para os mesmos valores de somatório de potência,  $\sum \mathbf{p} = 800\text{mW}$ , distribuídos de tal forma que resultam em um somatório ótimo.



**Figura 21: Evolução do somatório da potência de ALM-EE, MaMi-EE e SQP-EE quanto ao número de iterações.**

**Fonte: Autoria própria**

A Figura 22 mostra a convergência associada dos níveis de potência individuais para o ALM, SQP e MaMi em um sistema com  $K = 32$  usuários para cada uma das classes analisadas.

Em relação à optimalidade, o método MaMi novamente obteve uma melhor aproximação para os multiplicadores e, conseqüentemente, melhor qualidade da solução. Podemos continuar ressaltando que o método MaMi associado à linearização de restrições (C.2) do problema (60) resultou em uma abordagem alternativa interessante. De fato, o método MaMi possui características e vantagens interessantes para lidar com problemas de otimização quase-côncavos do tipo EE-OCDMA sujeitos a diferentes classes de serviços e restrições seletivas.

A Figura 23 apresenta as taxas alcançadas em relação à QoS mínima por classe após a respectiva convergência para os métodos ALM-EE, SQP-EE e MaMi-EE. Assim,

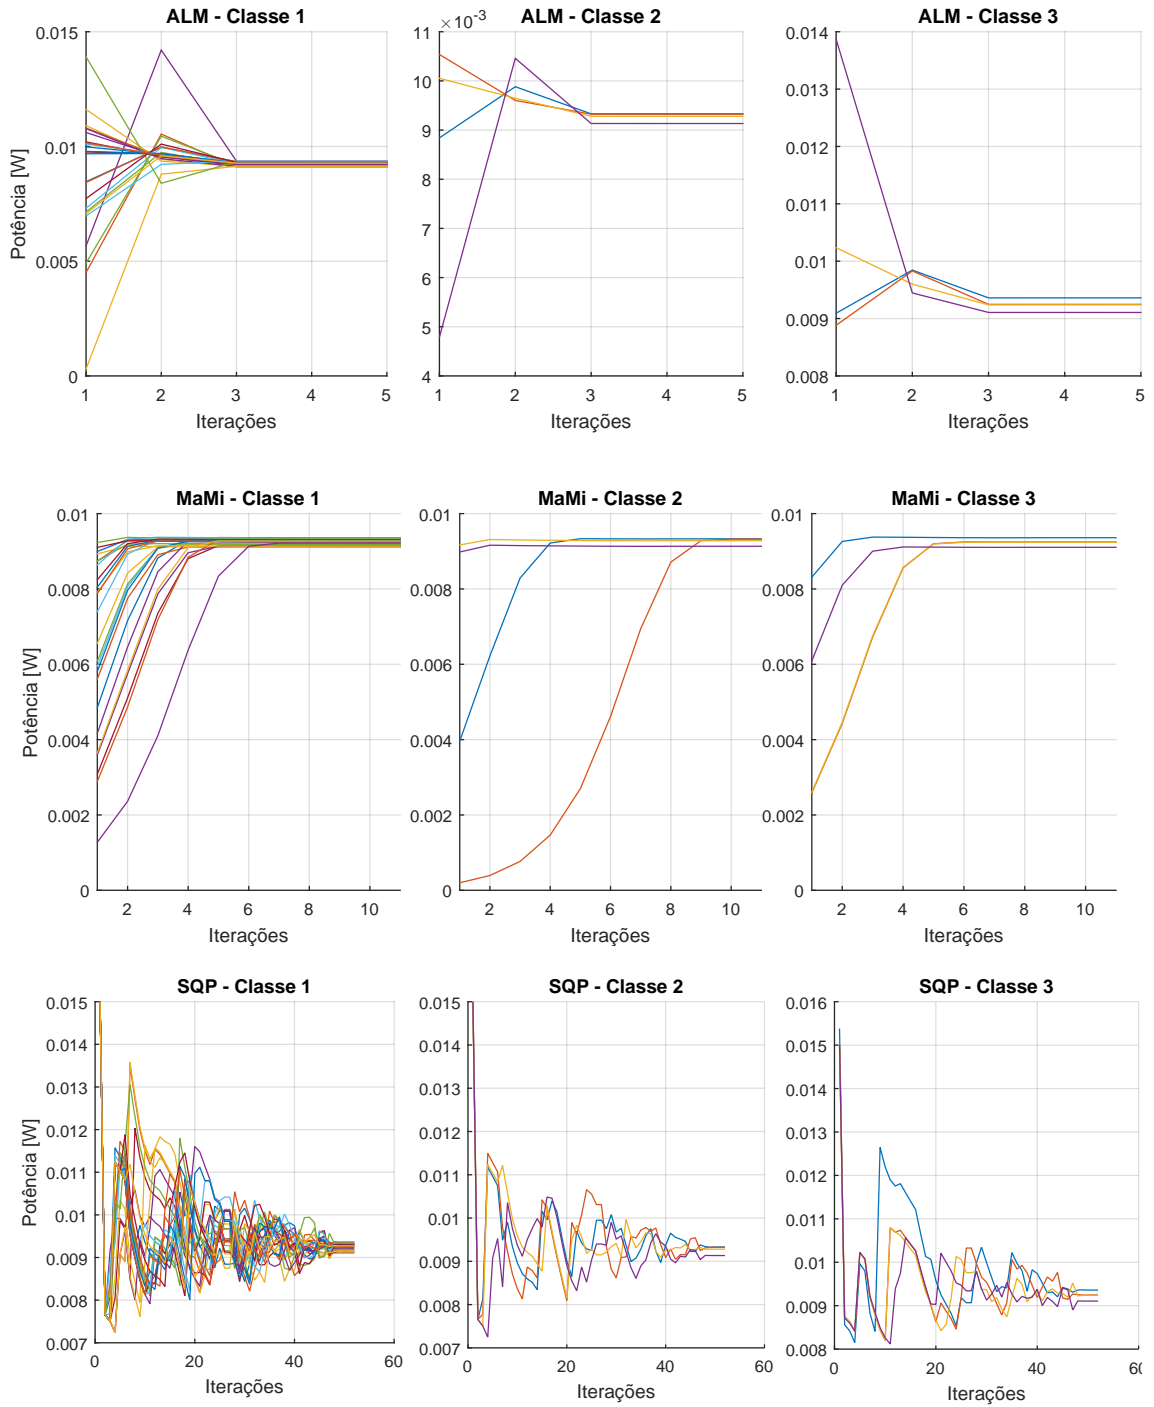
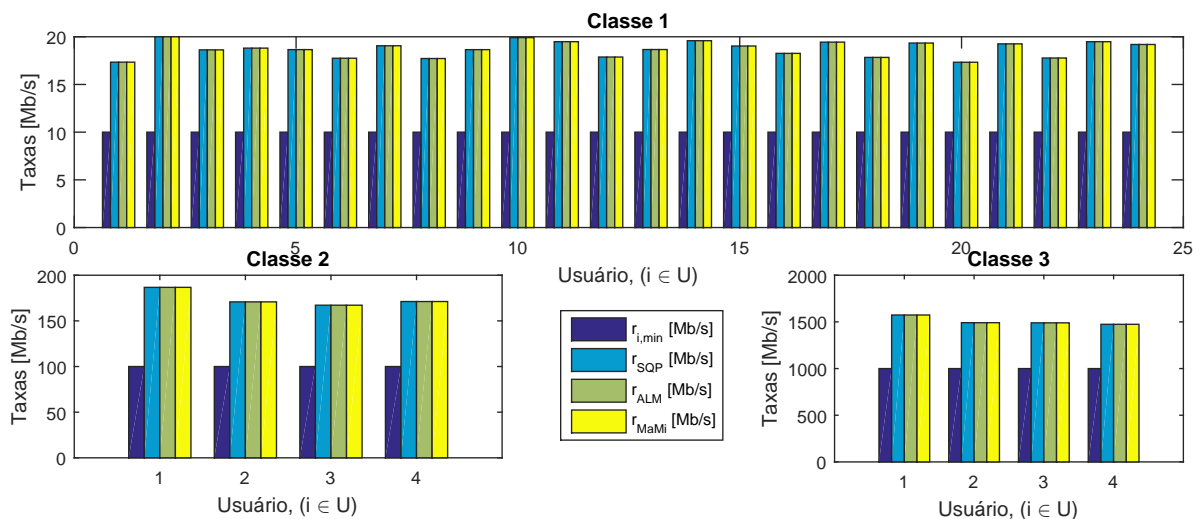


Figura 22: Convergência dos níveis individuais de potência para ALM, MAMI e SQP considerando  $K = 32 \in \{U^{\text{Classe 1}}; U^{\text{Classe 2}}, U^{\text{Classe 3}}\} \equiv [24; 4; 4]$  usuários.

Fonte: Autoria própria

para o Cenário B, todos os usuários operam sob a configuração máxima de  $EE$  satisfazendo suas respectivas QoS. Como a taxa de símbolos atingível é uma função monotonicamente crescente da potência de transmissão, a máxima taxa de serviço seria obtida ao inserir todos os usuários para transmitir com a potência máxima permitida no sistema. Assim o nível de MAI seria muito alto, e o somatório de taxas atingível neste caso seria sempre menor que o ótimo. Portanto, o procedimento de otimização de  $EE$  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. Observa-se que no ponto de equilíbrio obtém um valor razoável de  $gap$  entre a  $r_{\min}^{serv}$  associadas às QoS alvos e as taxas alcançadas.



**Figura 23:** Taxas mínimas atingidas para  $K = 32 \in \{U^{\text{Classe 1}}; U^{\text{Classe 2}}, U^{\text{Classe 3}}\} \equiv [24; 4; 4]$  usuários após convergência.

Fonte: Autoria própria

#### 4.4 TEMPO DE EXECUÇÃO EM CENÁRIOS DIFERENTES

Os esquemas propostos para alocação de recursos não aumentam o tempo programado nos protocolos PONs. Esses esquemas podem ser integrados dentro da alocação de largura de banda dinâmica, como ilustrado em (ALVES et al., 2016) ou executados durante o tempo de processamento fornecido nos outros protocolos de PON (HADI; PAKRAVAN, 2018). O esquema padrão de sinalização PON atualiza uma vez em cada ciclo através do monitoramento do status das ONUs; tal monitoramento tipicamente ocorre a cada milissegundo (HADI; PAKRAVAN, 2018), (ALVES et al., 2016).

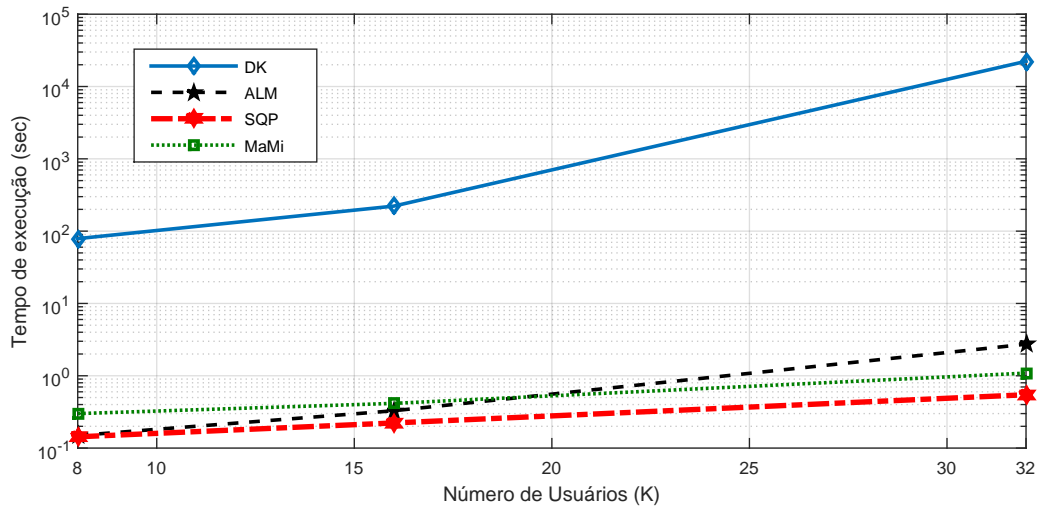
Além disso, o tempo de execução dos algoritmos de alocação de recursos depen-

dem também dos hardwares e softwares implementados nos nós ópticos (OLTs ou ONUs). Ademais, os esquemas de alocação de recursos propostos podem ser realizados de forma paralela, de acordo com o esquema de atualização da PON estabelecido em (HADI; PAKRAVAN, 2018), (ALVES et al., 2016).

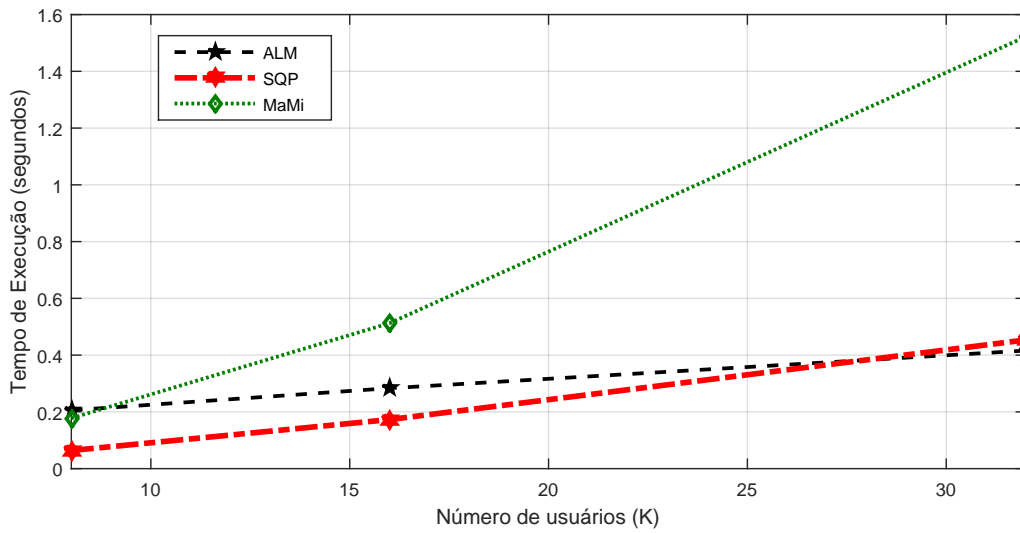
A Figura 24 compara a evolução do tempo de execução à medida que se aumenta o número de usuários na rede. Pode-se observar na Figura 24(a) que o método baseado em DK-CvX não é competitivo para o problema de otimização EE-OCDMA com grande número de nós ópticos. Enquanto os métodos ALM e SQP tiveram comportamento semelhante em relação ao tempo de execução no Cenário A, exceto em configurações de redes de alta dimensão, por exemplo,  $K = 32$  usuários, nos quais o tempo de execução do ALM aumenta substancialmente em relação ao método SQP. Com relação às soluções encontradas, podemos afirmar que as soluções obtidas pelo SQP possuem bons valores de optimalidade, uma vez que o próprio método estima os multiplicadores diferentemente do MaMi que utiliza de valores calculados a partir da solução encontrada. Portanto, consideramos que o método SQP resultou superior aos demais operando sob o Cenário A.

Comparando o consumo de tempo dos métodos de PNL mais promissores em um cenário de otimização mais desafiador, a Figura 24(b) ilustra a evolução do tempo de execução dos três métodos PNL promissores para o problema de otimização EE-OCDMA à medida que o número de usuários na rede OCDMA aumenta no Cenário B. Observe que o método de otimização baseado em DK-CvX não foi incluído devido à sua excessiva complexidade aliada a problemas de convergência quando o número de usuários é incrementado substancialmente. Por outro lado, os métodos ALM e SQP tiveram comportamento semelhante em relação ao tempo de execução reduzindo em relação ao método MaMi.

Das Figuras 19 e 23, pode-se inferir que a qualidade das soluções obtidas pelo SQP, ALM e MaMi resulta em valores de optimalidade similares, mesmo no mais sofisticado cenário, isto é, Cenário B. Assim, comparando esses valores de EE alcançados com o tempo de execução (complexidade) encontrado na Figura 24(b), pode-se concluir que entre os quatro otimizadores para o problema EE-OCDMA, baseados em distintos por classe analisados, o método SQP apresenta métrica de desempenho-complexidade superior aos demais.



a) Cenário A



b) Cenário B

Figura 24: Tempo computacional  $\times$  número de nós OCDMA para os métodos PNL de otimização: a) Cenário A; b) Cenário B.

Fonte: Autoria própria

## 4.5 CONCLUSÕES DO CAPÍTULO

Após a análise dos métodos de programação não lineares aplicados ao problema de otimização EE-OCDMA, pôde-se concluir que o método DK baseado em CvX demonstra não ser indicado para esta classe de problema quando a dimensão do problema (número de usuários) cresce, enquanto os métodos ALM, SQP e MaMi apresentaram comportamento de desempenho-complexidade adequados para o problema analisado, e os resultados indicam que em problemas com dimensões maiores a tendência de desempenho dos métodos devem ser mantidos. No Cenário B, onde a análise inclui multi-taxas, o método DK não obtém convergência, enquanto os demais métodos mantiveram comportamento similar ao observado no Cenário A.

Finalmente, os resultados numéricos demonstraram que os métodos de otimização SQP, ALM e MaMi constituem opções promissoras a serem implementadas na resolução do problema de otimização de eficiência energética do sistema OCDMA. Ainda, de acordo com os resultados numéricos obtidos e análises realizadas, os métodos SQP e ALM mostraram-se capazes de resolver de maneira eficiente o problema de otimização EE-OCDMA.

## 5 ESTRATÉGIAS HÍBRIDAS DE OTIMIZAÇÃO PARA A EFICIÊNCIA ENERGÉTICA EM REDES OCDMA

Os resultados obtidos no artigo (PENDEZA MARTINEZ et al., 2019) detalhados no Capítulo 4 para o problema EE são motivações para que neste capítulo seja investigado, de modo aprofundado, o método ALM aplicado ao problema de otimização da eficiência energética em redes OCDMA. Nesta investigação, exploramos alternativas para a resolução do subproblema gerado dentro do ALM com um método clássico quase-Newton baseado na estratégia de BFGS (NOCEDAL; WRIGHT, 2006) denominado ALM-BFGS, bem como a hibridação do ALM com métodos heurísticos, a saber PSO, e o método híbrido PSOGSA.

Neste contexto, métodos heurísticos evolutivos foram agregados na expectativa de incrementar o projeto de redes CDMA ópticas. Genericamente, uma meta-heurística é uma estratégia de busca que tenta explorar eficientemente o espaço de soluções possíveis para o problema. Esses algoritmos aproximados incorporam mecanismos para evitar mínimos ou máximos locais. O conhecimento específico do problema pode ser usado na forma de mecanismo heurístico para auxiliar no processo de busca e possivelmente acelerará a convergência em problemas de maiores dimensões. Uma variedade de meta-heurísticas foi desenvolvida e aplicada para resolver um grande número de problemas de otimização.

A escolha do método ALM deve-se a sua simplicidade de definição, execução e de suas boas propriedades teóricas, das quais podemos enfatizar que, em condições de regularidade adequadas para as funções que compõem o problema, o método converge para pontos que satisfazem às condições de optimalidade de Karush-Kuhn-Tucker portanto, se o método aplicado ao subproblema convergir para a solução global, o método do ALM convergirá para a solução global (ANDREANI et al., 2007a).

Vários trabalhos têm explorado o ALM associado a métodos heurísticos que, em síntese, usam o mecanismo heurístico-evolutivo para resolver o subproblema do ALM. Como exemplo, podem ser citados os trabalhos recentes (SAFARI et al., 2013), (SEDLAC-

ZEK; EBERHARD, 2006), os quais implementaram a meta-heurística PSO combinada ao método ALM para o problema de otimização em engenharia.

Neste capítulo, apresentamos uma modificação do algoritmo ALPSO proposto em (SEDLACZEK; EBERHARD, 2006) e o aplicamos ao problema de otimização EE, sendo este método proposto denominado ALM-PSO. Este método procura tirar proveito da estrutura quase convexa do problema, aproveitando-se da existência de uma solução única. Dessa forma, uma nova versão para o método ALPSO surge sem a preocupação de determinar a solução global entre várias soluções locais possíveis. Uma importante característica do ALM é que em cada iteração externa são atualizados o parâmetro de penalidade e os multiplicadores que auxiliam na busca da solução e contribuem para a velocidade de convergência. Além disso, utiliza-se a solução da iteração  $k$  como ponto inicial da iteração  $k + 1$ . Adaptamos esta característica para o ALM-PSO, deste modo para resolver o subproblema do ALM, consideramos o enxame inicial em uma região que depende da melhor solução e do nível de factibilidade e optimalidade alcançado no subproblema anterior. Além disso, consideramos neste capítulo as mesmas linhas de ALM-PSO com o PSOGSA híbrido, proposto em (MIRJALILI; HASHIM, 2010), denominado daqui em diante de método ALM-PSOGSA.

Neste contexto, a abordagem do ALM-PSO e ALM-PSOGSA são propostas como alternativas para problemas com restrições, em que a estratégia procura incorporar as propriedades teóricas do ALM com a eficiência dos métodos heurísticos.

Diversos trabalhos na literatura se dedicam a tratar códigos OCDMA considerando redes com número elevado de usuários. Dentre alguns trabalhos recentes, podemos destacar (MATEM et al., 2019), (KUMAWAT; MADDILA, 2017), (AHMED et al., 2017). Em (MATEM et al., 2019) considera-se uma rede que utiliza códigos 2D com correlação cruzada zero/ multi diagonal e é avaliada em termos de potência recebida, um número de 150 usuários e taxa de dados usando fotodiodo de avalanche (*ADP – Avalanche Photodiode*) e fotodiodo positivo intrínseco negativo (*PIN – Positive Intrinsic Negative*) para suprimir a MAI e reduzir o ruído de intensidade induzida por fase (*PIIN – Phase-Induced Intensity Noise*). Em (KUMAWAT; MADDILA, 2017) propõe-se um novo código com correlação cruzada zero (*ZCCC – Zero Cross Correlation Code*) e utiliza para testes uma rede com 50 usuários. Já em (AHMED et al., 2017) uma análise exata de relação sinal-ruído é realizada para o sistema de acesso múltiplo por divisão de código óptico (*SAC-OCDMA*) com detecção direta espectral (*SDD – Direct Detection Spectral*), os resultados dos testes consideram uma rede de 150 usuários.



Motivados por estes trabalhos, dentre outros da literatura que exploram redes OCDMA com grandes números de usuários, neste capítulo são exploradas técnicas para maximizar a EE-OCDMA para redes grandes, com 32, 64, 128 e 256 usuários.

## 5.1 MÉTODOS DE OTIMIZAÇÃO

Nesta seção, para maximizar o problema de EE (60), três métodos de otimização híbridos serão analisados, ALM-BFGS, ALM-PSO e ALM-PSOGSA. Da definição do problema EE-OCDMA (60), o conjunto de restrições de desigualdades é determinado pelas restrições (C.2), como visto em (PENDEZA MARTINEZ et al., 2019) (C.3) é mapeado por (C.2).

Vale ressaltar, como discutido no Capítulo 4, que a função objetivo a ser otimizada no problema EE pode ser classificada como um problema fracional não linear (WONG, 2012). Portanto, uma solução local que satisfaça as condições de optimalidade de Karush-Kuhn-Tucker é máxima se as funções do numerador e denominador forem diferenciáveis em uma vizinhança aberta. Essas características motivam o uso de métodos de PNL na determinação da solução do problema EE (PENDEZA MARTINEZ et al., 2019).

### 5.1.1 MÉTODO DE LAGRANGIANO AUMENTADO

De forma similar à Seção 4.1, apresentaremos resumidamente a forma como foi utilizado o método do Lagrangiano aumentado. Para o problema (60), dado um parâmetro de penalidade  $\rho > 0$  e  $\mu_i \geq 0$  aproximações para os multiplicadores de Lagrange, a função Lagrangiana aumentada, é definida como:

$$\mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu}) = J_2(\mathbf{p}) + \frac{\rho}{2} \sum_{i=1}^m \left[ [\gamma_i^* - \gamma(\mathbf{p})]^+ + \frac{\mu_i}{\rho} \right]^2, \quad [\alpha]^+ = \max[0, \alpha]. \quad (71)$$

Mais detalhes sobre a definição da função Lagrangiana aumentada pode ser encontrados em (ANDREANI et al., 2007a), (NOCEDAL; WRIGHT, 2006). A ideia central por trás do ALM é substituir a resolução direta do Problema (60) por uma sequência mais simples de subproblemas; portanto, métodos bem definidos aplicados a resolver problemas irrestritos podem ser adaptados.

Conforme comentado nos Capítulos 3 e 4, no método Lagrangiano aumentado, o parâmetro de penalidade é definido para ser pequeno nas primeiras interações externas, porque grandes parâmetros tendem a produzir subproblemas mal condicionados. O pseudocódigo para o método do Lagrangiano aumentado híbrido é apresentado no Algoritmo

8. Uma análise a respeito da convergência do ALM pode ser encontrada em (ANDREANI et al., 2007b).

**Algoritmo 8:** ALM-Método do Lagrangiano aumentado

1 Parâmetros de entrada:

2  $\tau \in [0, 1)$ ,  $\mu_{\max} > 0$ ,  $\nu \in (1, \infty)$ ,  $\mu_i^1 \in [0, \mu_{\max}]$ ,  $\forall i = 1, \dots, m$ , e tolerância  $\zeta > 0$ ;

3  $\{\varepsilon_k\} \subset \mathbb{R}_+$  uma sequência de parâmetros de tolerância de modo que

$$\lim_{k \rightarrow \infty} \varepsilon_k = 0. \quad (72)$$

$k = 0$ ;

4 **repita**

5 Resolução do Subproblema: Determine  $\mathbf{p}^k \in \mathbb{R}^K$  satisfazendo (no método Heurístico a primeira iteração externa utiliza o enxame definido na caixa  $p_{\min} \leq p_i \leq p_{\max}$ , para as demais iterações, considere o enxame inicial em uma vizinhança de  $\mathbf{p}^{k-1}$ . Para o método BFGS, a primeira iteração externa, inicialize com um ponto aleatório  $p^0$  na caixa  $p_{\min} \leq p_i \leq p_{\max}$ , nas demais iterações, inicialize com a solução anterior  $p^{k-1}$ )

$$\left\| \mathcal{P}(\mathbf{p}_k - \nabla \mathcal{A}(\mathbf{p}^k, \mu^k)) - \mathbf{p}^k \right\| \leq \varepsilon_k, \quad (73)$$

sendo  $\mathcal{P}$  é o operador de projeção na caixa  $p_{\min} \leq p_i \leq p_{\max}$ .

6 Se não for possível encontrar  $\mathbf{p}^k$  (73) pare a execução do algoritmo. Atualize os multiplicadores de Lagrange;

7

$$\mu_i^{k+1} = \max\{0, \mu_i^k + \rho_k(\gamma_i^* - \gamma_i(\mathbf{p}^k))\}, \quad i = 1, \dots, m \quad \text{e} \quad \mu_i^{k+1} \in [0, \mu_{\max}]$$

Atualize os parâmetros de penalidade.;

8

$$V_i^k = \max \left\{ (\gamma_i^* - \gamma_i(\mathbf{p}^k)), -\frac{\mu_i^k}{\rho_k} \right\}$$

$$\text{Se } \|V^k\|_{\infty} \leq \tau \|V^{k-1}\|_{\infty} \quad \text{então} \quad \rho_{k+1} = \rho_k.$$

$$\text{Caso contrário} \quad \rho_{k+1} = \nu \cdot \rho_k, \quad \text{sendo } \nu > 1.$$

$k \leftarrow k + 1$ ;

9 **até**  $\|\mathbf{p}^{k+1} - \mathbf{p}^k\| < \zeta$ ;

Se no ALM híbrido considerarmos que os métodos heurísticos empregados no subproblema garantem que as condições impostas em (73) sejam satisfeitas para alguma sequência  $\varepsilon_k$ , então  $\lim_{k \rightarrow \infty} \varepsilon_k = 0$ , então os resultados teóricos (NOCEDAL; WRIGHT, 2006) do ALM ainda são válidos.

### 5.1.2 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

O método PSO foi introduzido no ano de 1995, pelos pesquisadores Kennedy e Eberhart (M'FOUBAT et al., 2011). Basicamente, o PSO é um algoritmo de otimização inspirado na natureza, baseado no comportamento social de grupos de indivíduos, como pássaros e peixes. A população formada por partículas é iniciada aleatoriamente e cada uma representa uma possível solução para o problema. As partículas ocupam um espaço de dimensão  $N$ , guardando a informação histórica das melhores posições de todas as partículas. Usando as informações coletadas no processo de busca, as partículas tendem a se moverem em direção a melhor região ao longo do processo. Uma descrição completa do método PSO considerado neste trabalho pode ser encontrada em (M'FOUBAT et al., 2011).

O PSO pode ser resumido pelo modelo matemático que define a equação de velocidade (74) e a equação de posição (75)

$$v_i^{k+1} = \bar{w}v_i^k + c'_1 \times rand \times (pbest_i - x_i^k) + c'_2 \times rand \times (gbest_i - x_i^k) \quad (74)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1}, \quad (75)$$

$v_i^k$  é a velocidade da partícula  $i$  na iteração  $k$ ,  $\bar{w}$  é uma função de ponderação,  $c'_1$  é o coeficiente de confiança na partícula nela mesma,  $c'_2$  é o coeficiente de confiança da partícula em relação as outras partículas,  $rand$  é um número aleatório com distribuição uniforme no intervalo  $[0, 1]$ ,  $x_i^k$  é a posição corrente da partícula  $i$  na iteração  $k$ ,  $pbest_i$  é a melhor posição do agente  $i$  até a iteração  $k$  e  $gbest$  é a melhor posição assumida pelo enxame até a iteração  $k$ .

O termo  $\bar{w}v_i^k$  de (74) fornece capacidade de exploração para PSO. O termo  $c'_1 \times rand \times (pbest_i - x_i^k)$  e  $c'_2 \times rand \times (gbest_i - x_i^k)$  representam o pensamento individual e coletivo entre as partículas.

A seguir apresentamos os passos do PSO:

**Passo 1** Inicializar uma população de  $K$  indivíduos de dimensão  $D$ ;

**Passo 2** Determine o valor das constantes;

**Passo 3** Verificar se o critério de parada foi atingido, e esse critério pode ser um valor pré-determinado ou número de iterações. Se sim, finalizar o algoritmo;

**Passo 4** Sortear os números aleatórios *rand*;

**Passo 5** Determinar a melhor posição global e individual;

**Passo 6** Atualizar a velocidade das partículas;

**Passo 7** Atualizar as posições das partículas;

**Passo 8** Voltar ao passo 3.

### 5.1.3 MÉTODO DE OTIMIZAÇÃO POR BUSCA GRAVITACIONAL

O algoritmo GSA tem a característica de usar uma população inicial aleatória e definir uma estratégia para atualizar a população.

Esta estratégia é baseada nas leis da gravidade e movimento (KITAYAMA, 1998). Desta forma, os “agentes” são considerados como objetos e seu desempenho é medido por suas massas. Toda a massa atrai e é atraída por outras massas devido à força gravitacional, causando o movimento global de todo o conjunto (população) considerado. Assim, as massas cooperam usando uma forma direta de “comunicação”, a força gravitacional. As massas “pesadas”, que correspondem a boas soluções, movem-se mais lentamente que as mais leves. Cada massa possui quatro especificações (MUKHERJEE, 2000): posição, massa inercial, massa gravitacional ativa e massa gravitacional passiva. A posição da massa corresponde a uma solução candidata do problema de otimização, e suas massas gravitacionais e inerciais são determinadas usando a função objetivo. Uma descrição detalhada do método GSA pode ser encontrada em (KITAYAMA, 1998).

O método GSA é modelado inicialmente considerando um sistema com  $N$  agentes. O método inicia colocando aleatoriamente todos os agentes no espaço de busca. Durante as épocas, as forças gravitacionais do agente  $j$  no agente  $i$  em um tempo específico  $k$ ,  $F_{ij}^d(k)$ , são definidas como (RASHEDI et al., 2009):

$$F_{ij}^d(k) = G(k) \frac{M_{pi}(k) \times M_{aj}(k)}{R_{ij}(k) + \bar{\epsilon}} (x_j^d(k) - x_i^d(k)), \quad (76)$$

$M_{aj}$  é a massa gravitacional ativa relacionada ao agente  $j$ ,  $M_{pi}$  é a massa gravitacional passiva relacionada ao agente  $i$ ,  $G(k)$  é constante gravitacional no tempo  $k$ ,  $\bar{\epsilon}$  é uma pequena constante e  $R_{ij}(k)$  é a distância Eudlidiana entre dois agentes  $i$  e  $j$ ,  $x_i^d(k)$  é

a posição da partícula  $i$  na iteração  $k$ ,  $x_j^d(k)$  é a posição da partícula  $j$  na iteração  $k$ ; a função  $G(k)$  é calculada como:

$$G(k) = G_0 \exp \left[ \frac{-\alpha \cdot k}{maxiter} \right] \quad (77)$$

$\alpha$  e  $G_0$  são coeficientes decrescente e valor inicial respectivamente,  $k$  é a iteração atual e  $maxiter$  é o número máximo de iterações. Em um espaço de problema com a dimensão  $d$ , a força total que atua no agente  $i$  é calculada a partir de:

$$F_i^d(k) = \sum_{j=1, j \neq i}^N rand_j F_{ij}^d(k) \quad (78)$$

sendo  $rand_j$  um número aleatório com distribuição uniforme no intervalo  $[0,1]$ .

De acordo com a lei do movimento, a aceleração de um agente é proporcional à força resultante ao inverso de sua massa. A aceleração  $ac_i^d(t)$  do agente  $i$  na iteração  $k$  deve ser calculada da seguinte maneira:

$$ac_i^d(k) = \frac{F_i^d(k)}{M_{ii}(k)}, \quad (79)$$

$M_i$  é a massa do objeto  $i$ . Assim, as equações da velocidade e da posição dos agentes são:

$$v_i^d(k+1) = rand \times v_i^d(k) + ac_i^d(k) \quad (80)$$

$$x_i^d(k+1) = x_i^d(k) + v_i^d(k+1) \quad (81)$$

$v_i^d$  é a velocidade do agente  $i$  na iteração  $k$  e é a posição corrente da partícula  $i$  na iteração  $k$ .

O procedimento a seguir descreve o GSA:

**Passo 1** Inicializar as massas com valores aleatórios;

**Passo 2** Após inicialização, as velocidades para todas as massas são definidas usando (80);

**Passo 3** A constante gravitacional, forças totais e as acelerações são calculadas como (77), (78) e (80);

**Passo 4** As posições das massas são calculadas usando (81);

**Passo 5** O GSA para ao atingir o critério de parada;

---

#### 5.1.4 MÉTODO DE OTIMIZAÇÃO HÍBRIDO PSO GSA

A hibridação de algoritmos pode ser considerada uma estratégia que tenta superar certos problemas existentes nas diversas áreas da inteligência computacional. De acordo com (TALBI, 2002), dois algoritmos podem ser híbridos em nível alto ou baixo com o método de retransmissão ou evolução como homogêneo ou heterogêneo.

Proposta em (MIRJALILI; HASHIM, 2010), a hibridação PSO com GSA usa híbridos heterogêneos co-evolutivos de baixo nível. Os autores usam um híbrido de baixo nível porque dessa forma eles podem combinar as funcionalidades de ambos os algoritmos. O método é considerado coevolutivo porque não utiliza os dois algoritmos em sequência um do outro, mas ocorre em paralelo. A ideia básica do PSO GSA é combinar a capacidade de pensamento social (*gbest*) do método PSO com a capacidade de busca local do método GSA. Para combinar esses algoritmos é proposto o seguinte termo:

$$V_i(k+1) = \bar{w} \times V_i(k) + c'_1 \times rand \times ac_i(k) + c'_2 \times rand \times (gbest - X_i(k)), \quad (82)$$

$V_i(k+1)$  é a velocidade do agente  $i$  na iteração  $k+1$ ,  $c'_j$  é um fator de ponderação,  $\bar{w}$  é uma função de ponderação,  $rand$  é um número aleatório com distribuição uniforme no intervalo  $[0,1]$ ;  $ac_i(k)$  é a aceleração do agente  $i$  na iteração  $k$ , e  $gbest$  é a melhor posição assumida pelo enxame até a iteração  $k$ .

Em cada iteração, as posições das partículas são atualizadas como a seguinte equação:

$$X_i(k+1) = X_i(k) + V_i(k+1). \quad (83)$$

No método PSO GSA, a princípio, todas as partículas são inicializadas aleatoriamente. Cada partícula é considerada como uma potencial solução. Após a inicialização, a força gravitacional, a constante gravitacional e as forças resultantes entre as partículas são calculadas usando (76), (77), e (78) respectivamente. A cada iteração, a melhor solução é atualizada. Depois de calcular as acelerações com a atualização da melhor solução até

o momento, as velocidades de todos os agentes podem ser calculadas usando (82). Finalmente, as posições de agentes são definidos como (83). O processo de atualização de velocidades e as posições serão interrompidas ao atender um critério final.

O procedimento a seguir oferece uma descrição para o PSOGSA:

---

**Passo 1:** Inicializar as partículas com valores aleatórios;

**Passo 2:** Após inicialização, a força gravitacional, a constante gravitacional e as forças resultantes entre as partículas são calculadas usando (76), (77), e (78) respectivamente;

**Passo 3:** Calculam-se as acelerações das partículas, de acordo com (79) e (80);

**Passo 4:** Atualiza-se a melhor solução até o momento e as velocidades de todos os agentes são calculados de acordo com (82);

**Passo 5:** Repetir até atingir o critério de parada.

---

A qualidade das soluções (*fitness*) são consideradas no procedimento de atualização. Os agentes perto de boas soluções tentam atrair os outros agentes que estão explorando o espaço de busca. Quando todos os agentes estão próximos de uma boa solução, eles se movem muito devagar. Neste caso, o *gbest* os, ajuda a explorar o ótimo global. PSOGSA usa uma memória *gbest* para salvar a melhor solução encontrada até agora, por isso é acessível a qualquer momento. Cada agente pode observar a melhor solução até agora e tendem para isso. Com o ajuste de  $c'_1$  e  $c'_2$ , as habilidades de busca global e busca local podem ser equilibradas.

### 5.1.5 MÉTODO BFGS

De acordo com (NOCEDAL; WRIGHT, 2006) o método BFGS, proposto por Broyden, Fletcher, Goldfarb e Shanno, é o algoritmo quase-Newton mais popular. Para o problema  $\max_{\mathbf{p} \in \Omega} f(\mathbf{p})$ , o método considera a seguinte função quadrática em relação a  $d$ :

$$\bar{f}(\mathbf{d}) = f_k + \nabla f_k^T \mathbf{d} - \frac{1}{2} \mathbf{d}^T \mathbf{B}^k \mathbf{d}, \quad (84)$$

$\mathbf{B}^k$  é uma matriz simétrica definida negativa que é atualizada em cada iteração. Note que em  $\mathbf{d} = \mathbf{0}$  o valor da função  $\bar{f}$  e o gradiente  $\nabla \bar{f}$  em (84) correspondem a  $f_k$  e  $\nabla f_k$ .

O mínimo  $\mathbf{d}_k$  deste modelo quadrático côncavo pode ser escrito explicitamente como

$$\mathbf{d}^k = - (\mathbf{B}^k)^{-1} \nabla f_k = - \mathbf{H}^k \nabla f_k, \quad (85)$$

sendo  $\mathbf{B}_k$  uma matriz negativa definida,  $\mathbf{d}_k$  é uma direção de subida para o problema de  $f(\mathbf{p})$ . Assim, uma atualização para  $\mathbf{p}$  pode ser dado por:

$$\mathbf{p}^{k+1} = \mathbf{p}^k + a_k \mathbf{d}^k \quad (86)$$

e o critério  $a_k$ , tamanho do passo na  $k$ -ésima iteração na direção de busca, é atribuído com a finalidade de satisfazer as condições de Wolfe.

Na sequência, definimos a notação de vetores

$$\mathbf{s}^k = \mathbf{p}^{k+1} - \mathbf{p}^k = a_k \mathbf{d}^k, \quad \mathbf{y}^k = \nabla f_{k+1} - \nabla f_k. \quad (87)$$

Então,

$$\mathbf{B}^{k+1} \mathbf{s}^k = \mathbf{y}^k. \quad (88)$$

Para definirmos o algoritmo BFGS, precisamos de uma alternativa inicial para a matriz  $\mathbf{H}_k$ , por simplicidade utilizamos uma matriz identidade.

Usando a fórmula de Sherman-Morrison-Woodbury, podemos derivar a seguinte expressão para uma atualização da matriz Hessiana  $\mathbf{H}_k$ :

$$\mathbf{H}^{k+1} = \mathbf{H}^k - \frac{\mathbf{H}^k \mathbf{y}^k (\mathbf{y}^k)^T \mathbf{H}^k}{(\mathbf{y}^k)^T \mathbf{H}^k \mathbf{y}^k} + \frac{\mathbf{s}^k (\mathbf{s}^k)^T}{(\mathbf{y}^k)^T \mathbf{s}^k}. \quad (89)$$

Note que os dois últimos termos no lado direito de (89) são matrizes de posto um, de modo que  $\mathbf{H}^k$  sofre uma modificação de posto 2.

O Algoritmo 9 descreve um pseudocódigo para o método BFGS aplicado ao sub-problema do ALM



**Algoritmo 9:** Método - BFGS

```

1 Entrada: Dado o ponto inicial  $x_0$ , tolerância de convergência  $\zeta > 0$ , Aproximação
da inversa da Hessiana  $\mathbf{H}_0$ ;
2  $k = 0$ ;
3 repita
4   Calcule as direções de busca ;
5    $\mathbf{d}^k = -\mathbf{H}^k \nabla f_k$ ;
6   Calcule  $\mathcal{P}(\mathbf{p}^k + a_k \mathbf{d}^k)$ , sendo  $\mathcal{P}$  denota a projeção ortogonal em
 $p_{\min} \leq p_i \leq p_{\max}$ ;
7   Defina  $\mathbf{s}^k = \mathbf{p}^{k+1} - \mathbf{p}^k$  e  $\mathbf{y}^k = \nabla f_{k+1} - \nabla f_k$ ;
8   Atualize  $\mathbf{H}^{k+1} = \mathbf{H}^k - \frac{\mathbf{H}^k \mathbf{y}^k (\mathbf{y}^k)^T \mathbf{H}^k}{(\mathbf{y}^k)^T \mathbf{H}^k \mathbf{y}^k} + \frac{\mathbf{s}^k (\mathbf{s}^k)^T}{(\mathbf{y}^k)^T \mathbf{s}^k}$  ;
9    $k \leftarrow k + 1$ .
10 até  $\|\nabla f_k\| < \zeta$ ;

```

## 5.2 ASPECTOS DE IMPLEMENTAÇÃO DOS MÉTODOS DE OTIMIZAÇÃO PARA EE-OCDMA

Nesta seção são apresentados os principais aspectos em relação à implementação dos métodos descritos na Seção 5.1. Esta implementação para o ALM inclui uma melhor estimativa do parâmetro de penalidade e adapta de forma inédita o ALM com meta-heurísticas.

O algoritmo ALM, conforme discutido na Subseção 5.1.1, foi inicializado com os multiplicadores como zeros e um ponto aleatório  $\mathbf{p}^0$  satisfazendo a restrição (C.3), o parâmetro de penalidade calculado por meio da fórmula (ANDREANI et al., 2007a):

$$\rho_o = \max \left\{ 10^{-6}, \min \left\{ 10, \frac{|2f(\mathbf{p}^0)|}{\|\max\{0, \mathbf{g}(\mathbf{p}^0)\}\|^2} \right\} \right\}.$$

Portanto, como os multiplicadores iniciais são nulos, o peso da função objetivo e o peso da infactibilidade são iguais na função objetivo do primeiro subproblema.

Inspiradas nas características do ALM, neste trabalho é proposta a seguinte adaptação para ALMPSO e ALMPSOGSA: dada a solução do subproblema  $\mathbf{p}^k$ , definimos a posição inicial (população) para o subproblema seguinte como uma perturbação de  $\mathbf{p}^k$ , cuja distância máxima é determinada proporcionalmente pela factibilidade e optimalidade, conforme (73).

Por definição, o ALM calcula as aproximações para os multiplicadores e a optimalidade é determinada a partir do valor do gradiente da função Lagrangiana (71), sendo

esta dada por:

$$\Theta = \|\mathcal{P}(\mathbf{p}^k - \nabla \mathcal{L}(\mathbf{p}^k, \boldsymbol{\mu}^k)) - \mathbf{p}^k\| = \|\mathcal{P}(\mathbf{p}^k - \nabla J_2(\mathbf{p}^k) - \sum_{i=1}^K \mu_i^k \nabla \gamma_i(\mathbf{p}^k)) - \mathbf{p}^k\| \rightarrow 0 \quad (90)$$

no ponto  $\mathbf{p}^k$  com a respectiva aproximação dos multiplicadores.

A factibilidade no contexto será considerada como  $\mathcal{F}_i^k = [\gamma_i^* - \gamma_i]^+ = \max\{0, \gamma_i^* - \gamma_i\}$ , se  $p_{\min} \leq p_i \leq p_{\max}$ , portanto, o valor nulo da factibilidade indica que as restrições (C.1) e (C.2) são satisfeitas e, conseqüentemente, (C.3) é também satisfeita.

Espera-se que o subproblema se torne mais fácil à medida que atualizamos os parâmetros e aplicamos a estratégia anterior. Assim, os métodos heurísticos utilizam o número máximo de iterações igual a 250 para cada subproblema e diminuimos este máximo após cada iteração externa.

Consideramos que um ponto é factível se  $\max\{\mathcal{F}_1^k, \mathcal{F}_2^k, \dots, \mathcal{F}_K^k\}$ , na  $k$ -ésima iteração, é menor que  $10^{-4}$ . Interrompemos a execução do método se for obtido  $\mathbf{p}^k$  factível com optimalidade menor que  $10^{-4}$ , ou se  $\mathbf{p}^k$  é factível e  $\|\mathbf{p}^k - \mathbf{p}^{k-}\| < 10^{-6}$ .

### 5.3 RESULTADOS NUMÉRICOS

Nesta seção, apresentamos os resultados obtidos nos testes numéricos realizados considerando topologias de redes realísticas do Capítulo 4, Seção 4.2 baseada em códigos MLEWHPC2D, que suportam diferentes classes operando sob diferentes níveis de QoS e taxa de bits alcançáveis como descrito na Seção 2.1. Os principais valores dos parâmetros do sistema estão resumidos na Tabela 11. Os valores dos parâmetros algorítmicos são mostrados na Tabela 12. Os parâmetros considerados para o PSO e PSOGSA são recomendados por (RAO, 2009) e (MIRJALILI; HASHIM, 2010). Os testes foram realizados no MatLab 8.0, Windows 10 Home Language, versão 1703, CPU Intel Core i7-7700HQ a 2.80GHz, 16.00GB de RAM instalada, sistema operacional 64 bits. A determinação do número de FLOPs foi obtida por meio de uma adaptação do programa Contour FLOPS de Hang Qian<sup>1</sup>. No final da seção, é exibida uma comparação entre os métodos ALM-BFGS  $\times$  ALM-PSO  $\times$  ALM-PSOGSA.

---

<sup>1</sup>Disponível para download em [se.mathworks.com/matlabcentral/fileexchange/50608-counting-the-floating-point-operations-flops](https://se.mathworks.com/matlabcentral/fileexchange/50608-counting-the-floating-point-operations-flops)

**Tabela 11: Parâmetros da rede adotados**

	Valores dos parâmetros
Ineficiência do Transponder	$\iota = 2,7\text{W/Gbps}$
Ruído branco	$\sigma = 0,032\text{dB}$
Constante de Planck	$h = 6,63 \times 10^{-34} \text{ J/Hz}$
Período de Chip	$T_c = 9 \text{ ps}$
Comprimento da distância	do link $[4, 100] \text{ km}$
Max. potência do laser	$p_{\max} = 20 \text{ dBm}$
Min. potência do laser	$p_{\min} = [p_{\max} - 90] \text{ dBm}$
SINR	$\gamma_i^* = 20\text{dB}$
<b>“serv” = {Classe 1, Classe 2 e Classe 3}</b>	
Usuários por classes	$K \in \{U^{\text{CLASSE 1}}, U^{\text{CLASSE 2}}, U^{\text{CLASSE 3}}\}$
$U = [32, 64, 128, 256] :$	$\{[24; 4; 4], [24; 24; 16], [64; 35; 29], [128; 71; 57]\}$
Min. user rate	$r_{\min}^{\text{serv1}} = 10 \text{ Mbps}$ $r_{\min}^{\text{serv2}} = 100 \text{ Mbps}$ $r_{\min}^{\text{serv3}} = 1 \text{ Gbps}$
Comprimento da Sequência	$F_i = \frac{T_b}{T_c} \in \{1331, 121, 11\}$

**Tabela 12: Parâmetros adotados de entrada de algoritmo**

<b>ALM</b>	
Fator de penalidade 1	$\nu = 10$
Fator de penalidade 2	$\tau = 10^{-1}$
Limite do multiplicador de Lagrange	$\mu_{\max} = 10^{+6}$
<b>PSO</b>	
Peso Inercial	$w = 1$
Taxa de amortecimento de peso de inércia	$w_{\text{damp}} = 0,99$
Coefficiente de Aprendizagem Pessoal	$c_1 = 5$
Coefficiente Global de Aprendizagem	$c_2 = 1,5$
Número máximo de iterações	$\text{maxiter} = \min\{\max\{75, 50 + 25 \times k\}, 150\}$
<b>PSOGSA</b>	
Número máximo de iterações	$\text{maxiter} = \min\{\max\{75, 50 + 25 \times k\}, 150\}$
Parâmetros do PSO	$w = 1$ $w_{\text{damp}} = 0,99$ $c_1 = 5$ $c_2 = 1,5$
Parâmetros do GSA	$G_0 = 1$ $\alpha = 23$
<b>BFGS</b>	
Aproximação inicial da matriz Hessiana	$\mathbf{H}_0 = I$

### 5.3.1 OTIMIZAÇÃO DE EE COM RESTRIÇÃO NO SERVIÇO DE TAXA MÍNIMA ( $R_{\text{MIN}}^{\text{SERV}}$ )

Considerando os parâmetros descritos anteriormente na Tabela 11 com três classes de serviço, e  $K = 32, 64, 128$  e  $256$  usuários, o desempenho dos três algoritmos EE-OCDMA é comparado em termos de: a) tempo de execução; b) valor máximo de eficiência energética; c) número de iterações; d) factibilidade; e) optimalidade.

Para realizar os testes, consideramos os seguintes tamanhos iniciais de população: para 32 usuários  $N = 80$ , 64 usuários  $N = 100$ , 128 usuários  $N = 120$  e 256 usuários  $N = 240$ . O tamanho da população foi escolhido com base na dimensionalidade do problema.

**Tabela 13: Tempo de execução, valor EE atingível, número de iterações para convergência, factibilidade e optimalidade para os algoritmos EE-OCDMA, considerando o aumento do número de nós ópticos**

Método	Tempo[s]	FuncCont	FLOPS	$J_2(\mathbf{p})$ $\left[\frac{\text{bit}}{\text{Joule}}\right]$	Iter.	$\mathcal{F}$	$\Theta$
<b>32 usuários</b>							
ALM-PSO	1,623821	40877	$1,4075 \times 10^{+8}$	$5,6860 \times 10^{+11}$	<b>3</b>	0	0,0094
ALM-PSOGSA	8,943019	60402	$1,0203 \times 10^{+11}$	$5,6860 \times 10^{+11}$	5	0	<b>0,0067</b>
ALM-BFGS	<b>0,495164</b>	<b>17195</b>	$7,6591 \times 10^{+7}$	$5,6860 \times 10^{+11}$	4	0	0,0092
<b>64 usuários</b>							
ALM-PSO	4,937426	76840	$6,7433 \times 10^{+8}$	$4,9838 \times 10^{+11}$	4	0	0,0108
ALM-PSOGSA	24,045129	75786	$3,7817 \times 10^{+12}$	$4,9837 \times 10^{+11}$	4	0	0,0112
ALM-BFGS	<b>1,384031</b>	<b>44059</b>	$4,2625 \times 10^{+8}$	$4,9838 \times 10^{+11}$	<b>2</b>	0	<b>0,0001</b>
<b>128 usuários</b>							
ALM-PSO	<b>90,059982</b>	1048654	$3,5719 \times 10^{+10}$	$4,8616 \times 10^{+11}$	30	0	0,0898
ALM-PSOGSA	318,569198	<b>457212</b>	$4,9366 \times 10^{+13}$	$4,8617 \times 10^{+11}$	<b>13</b>	0	<b>0,0894</b>
ALM-BFGS	-	-	$3,2702 \times 10^{+11}$	-	-	-	-
<b>256 usuários</b>							
ALM-PSO	<b>301,019030</b>	3273326	$3,9108 \times 10^{+11}$	$4,6224 \times 10^{+11}$	45	0	<b>0,0893</b>
ALM-PSOGSA	4935,544555	<b>1717677</b>	$3,4783 \times 10^{+15}$	$4,6229 \times 10^{+11}$	<b>25</b>	0	0,0898
ALM-BFGS	-	-	$7,9733 \times 10^{+11}$	-	-	-	-

Observando a Tabela 13, os resultados mostram que a estratégia de inicialização do exame torna o comportamento do ALM-PSO ou PSOGSA bem próximo do ALM-BFGS para  $K = 32$  e  $K = 64$  usuários. Para  $K = 128$  e  $K = 256$ , o método ALM-BFGS não conseguiu obter factibilidade dentro do número máximo das iterações previstas. Vale a pena ressaltar que o desempenho do método ALM-BFGS poderia ser melhorado adotando-se a técnica *multi-start* (ANDREANI et al., 2007a) com o intuito de melhorar a robustez do método, porém a estratégia de *multi-start* elevaria consideravelmente o tempo computacional. Em relação à complexidade algorítmica, podemos destacar que o método híbrido

PSOGSA consumiu maior número de FLOPS em relação ao PSO. Podemos concluir ainda que o método ALM-PSO seja a variação mais indicada do ALM para o problema EE-OCDMA com grande número de usuários. Destacamos que a estratégia de inicialização do enxame próxima da solução anterior pode não ser indicada quando buscamos a solução global em um problema com diversas soluções locais. *FuncCont* denota o número de vezes que os métodos de otimização calculam o valor de  $J_2$  e SINR para um determinado valor de  $\mathbf{p}$ . Podemos observar ainda que para 128 e 256 usuários o método ALM-PSOGSA consome número menor de iterações externas obtendo soluções com valores de  $J_2$  ligeiramente melhores.

A Figura 25 mostra a evolução da convergência de EE para os três métodos e diferentes números de nós ópticos. Observe que para cenários mais complexos, com um número elevado de usuários, por exemplo,  $K = 128$  e  $256$ , o método ALM-BFGS diverge após a terceira iteração, os vetores  $\mathbf{p}^k$  obtidos pelo método permanecem em uma região infactível na qual foi observado pouca variação de  $J_2$ . Assim o método atingiu o número máximo de iterações estabelecidas sem obter convergência. A Figura 26 apresenta a curva de EE para  $K = 32, 64, 128$  e  $256$  considerando a primeira coordenada de  $\mathbf{p}$  como uma variável e as demais fixas no valor de solução. Pode-se observar que o máximo valor indicado de EE é o mesmo para o valor máximo de EE apresentado na Figura 25. Nota-se que há uma deterioração da eficiência energética geral da rede OCDMA conforme o número de usuários aumenta, uma vez que o efeito MAI aumenta proporcionalmente. Portanto, o controle da potência é fundamental para obter uma qualidade de serviço mínima, enquanto minimiza simultaneamente a MAI. A Figura 27 mostra a evolução do número de FLOPS consumidos dos métodos ALM-PSO, ALM-BFGS e ALM-PSOGSA. Fica claro que o método ALM-PSO é mais indicado para o problema EE-OCDMA uma vez que a complexidade do método ALM-PSOGSA pode tornar o método inviável para redes ainda maiores, enquanto o ALM-BFGS não convergiu sob elevados carregamentos, isto é,  $K \geq 128$ . A Figura 28 mostra a evolução da soma das potências versus o número de iterações obtidas pelos métodos ALM-PSO, ALM-PSOGSA e ALM-BFGS para  $K = 32$  nós ópticos distribuídos em três classes de serviço,  $\{U^{\text{CLASSE 1}}; U^{\text{CLASSE 2}}; U^{\text{CLASSE 3}}\} \equiv [24; 4; 4]$  usuários. Os três métodos convergem para os mesmos valores de consumo de soma de potência do laser de  $P_T = 800\text{mW}$ , distribuídos de tal forma que resulta em um valor ótimo (máximo) de EE. Observe que sob tais condições de operação, o comportamento para o consumo de potência com alterações mais suaves e de menor amplitude ao longo das iterações até a convergência é obtido pelo método ALM-PSO. O ALM-BFGS e o ALM-PSOGSA ultrapassam a potência total consumida ( $P_T$ ) ao longo do maior número de iterações antes

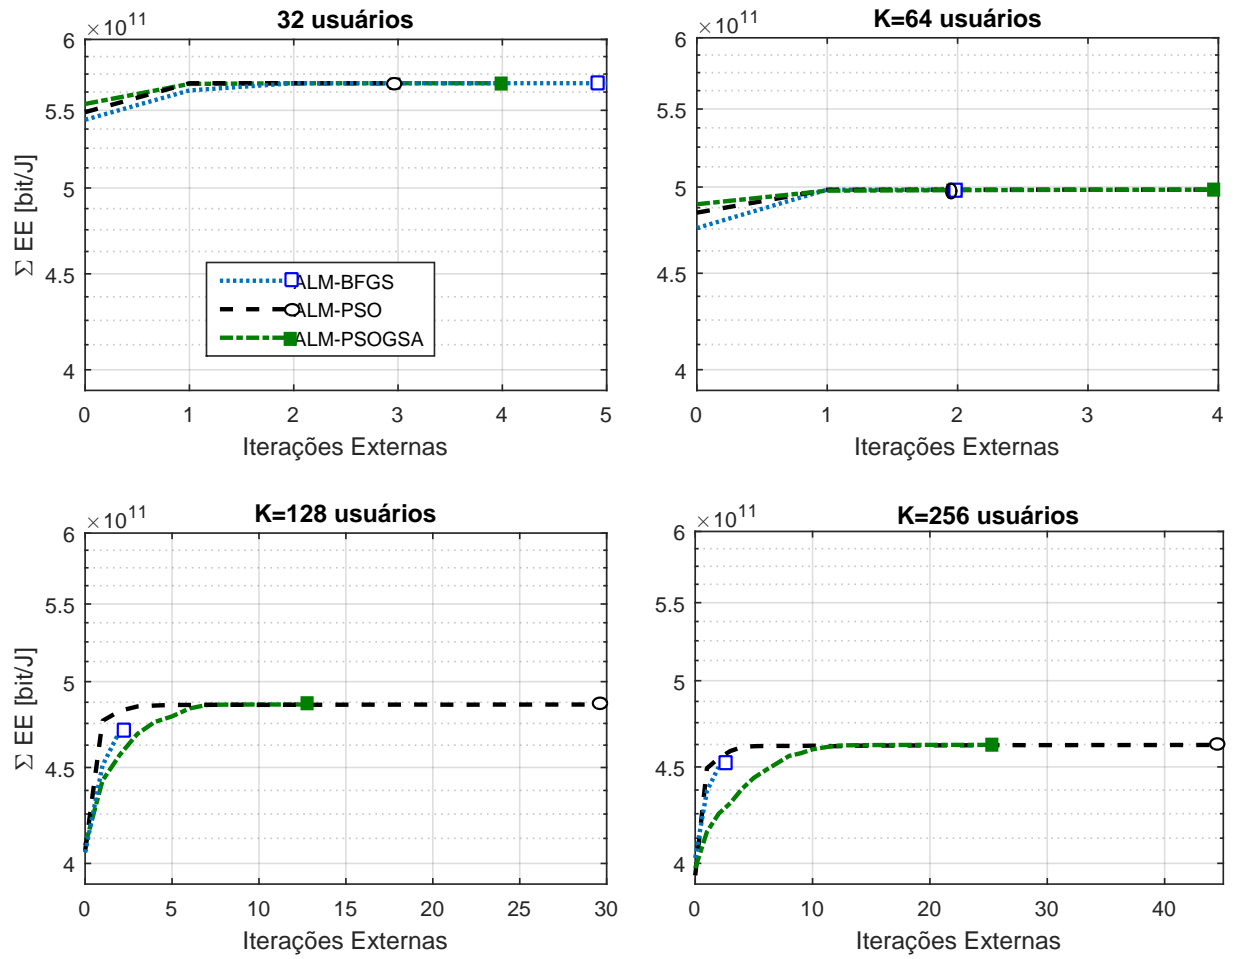


Figura 25: Convergência para o problema de EE e considerando diferentes métodos de otimização e número de usuários  $K \in \{32; 64; 128; 256\}$ .

Fonte: Autoria própria





Figura 26: Curvas de EE para  $p_2^*, \dots, p_k^*$  fixos e  $p_1$  variando. Comportamento Fracional de  $J_2$ .

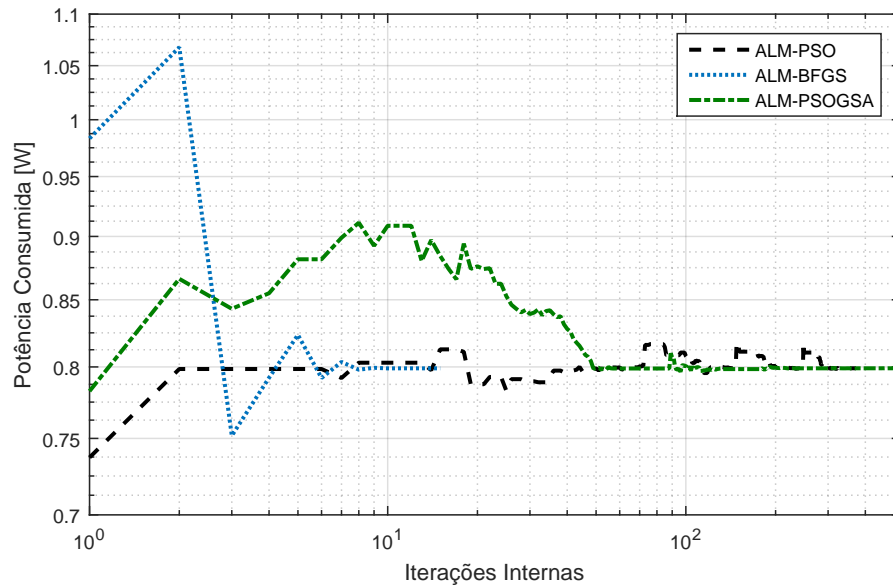
Fonte: Autoria própria



**Figura 27:** FLOPs consumidos aumentando com o número de nós para os três métodos de otimização de EE-OCDMA.

Fonte: Autoria própria

de convergirem. A Figura 29 apresenta a evolução individual para os níveis de potência



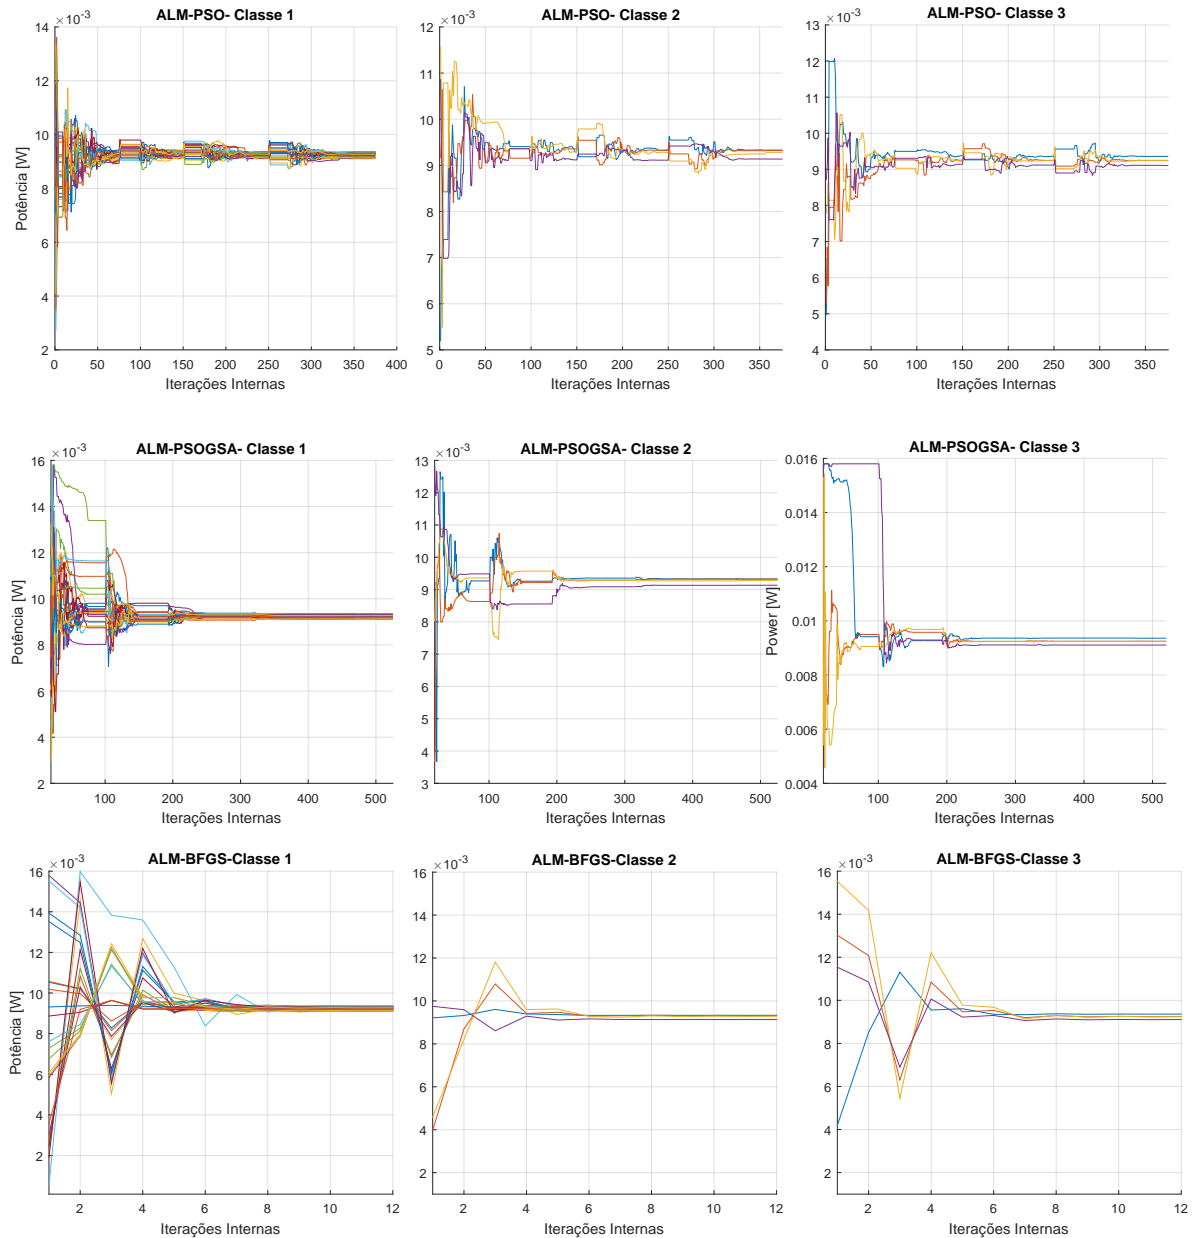
**Figura 28:** Evolução da potência alocada *versus* iterações para os métodos ALM-PSO, ALM-PSOGSA e ALM-BFGS. Recurso de Potência Total de  $P_t = 800\text{mW}$ .

Fonte: Autoria própria

para cada uma das classes analisadas. Destacamos a Classe 1 do método ALM-PSOGSA,



na qual é observada, após as primeiras iterações externas, o efeito da atualização dos multiplicadores e do parâmetro de penalidade nas iterações internas. O novo enxame faz com que ocorra mudança na tendência da evolução dos níveis de potência, e os direciona efetivamente para a solução.

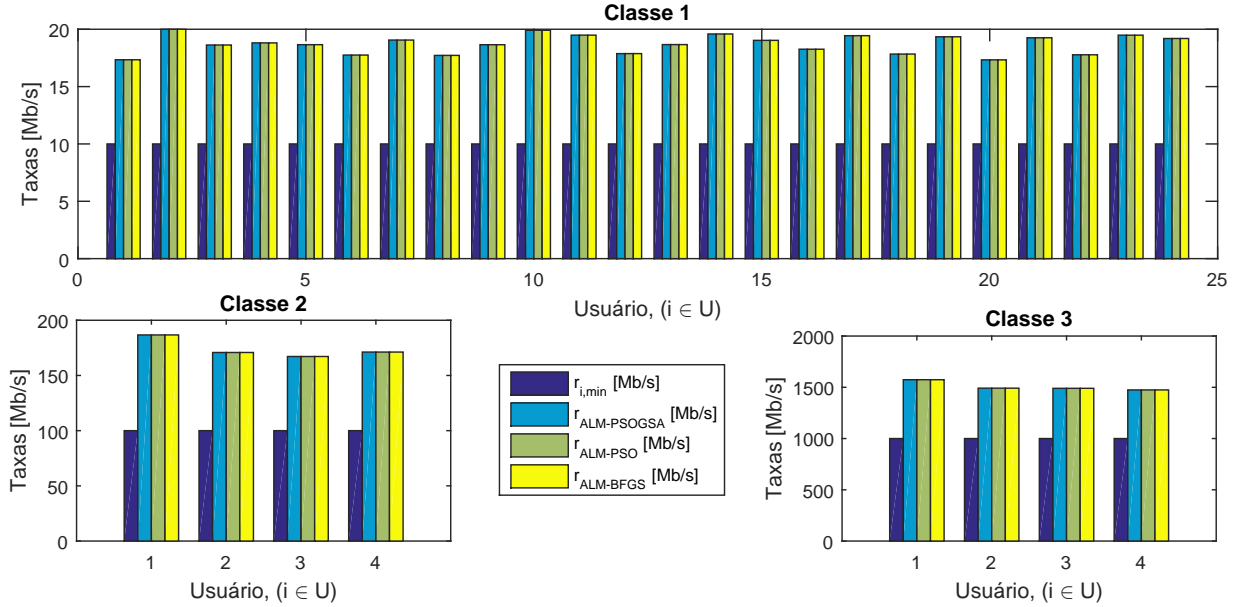


**Figura 29:** Convergência de níveis de potência individuais para ALM-PSO, ALM-PSOGSA e ALM-BFGS, considerando  $K = 32 \in \{U^{\text{Classe 1}}; U^{\text{Classe 2}}, U^{\text{Classe 3}}\} \equiv [24; 4; 4]$  usuários.

**Fonte:** Autoria própria

A Figura 30 representa as taxas alcançadas em relação à QoS mínima por classe após a respectiva convergência para ALM-PSO, ALM-PSOGSA e ALM-BFGS. Assim,

todos os usuários de  $K = 32$  operam sob a configuração máxima de  $\sum EE$  satisfazendo suas respectivas QoS. Note que no ponto de equilíbrio obtém-se um valor razoável de  $gap$  entre a  $r_{\min}^{serv}$  associadas às QoS alvos e as taxas alcançadas.



**Figura 30:** Taxas mínimas e alcançáveis para  $K = 32 \in \{U^{\text{Classe 1}}; U^{\text{Classe 2}}, U^{\text{Classe 3}}\} \equiv [24; 4; 4]$  usuários após a convergência

Fonte: Autoria própria

### 5.3.2 COMPARAÇÃO COM OUTROS MÉTODOS META-HEURÍSTICOS

Nesta subseção, a resolução do problema de eficiência energética em OCDMA, como originalmente apresentada em (60), é comparada, levando em consideração diferentes meta-heurísticas. O método PSO apresentado em (DURAND; ABRAO, 2017) foi implementado para resolver o problema EE em redes OCDMA e, aqui comparado com nossa proposta do PSOGSA. Para os testes, consideramos uma função custo usual com base na penalidade e considerou-se os mesmos parâmetros apresentados nas Tabelas 8 e 12. Além disso, utilizamos o mesmo tamanho de população inicial definida na Seção 5.3.1. Para complementar a análise apresentamos o desempenho do método ALPSO nos cenários já considerados na Subseção 5.3.1.

Os resultados numéricos obtidos pelos métodos PSO e PSOGSA para o problema (60) considerando os parâmetros descritos na Tabela 8, incluem o desempenho dos métodos heurísticos até 3000 iterações. Este valor equivale-se ao máximo de 50 iterações considerados na subseção 5.3.1. Para melhor análise apresentam-se os resultados parciais

ao término de 250, 500, 1000, 2000 e 3000 iterações.

Os resultados para tempo de execução, valor EE atingível e factibilidade para os algoritmos PSO e PSO-GSA nas Tabelas 14, 15, 16 e 17, respectivamente, demonstram que, para um número médio de usuários de 32 e 64, as meta-heurísticas atingiram desempenho próximo dos métodos ALM-PSO e ALM-PSO-GSA e repetem as soluções apresentadas na Tabela 13. No entanto, com o aumento do número de usuários, ambas as meta-heurísticas não atingem a solução, para 128 usuários, o PSO e o PSO-GSA chegam a se aproximar da solução apresentada na Tabela 13. Para  $K = 256$ , ambas as heurísticas não são capazes de atingir essa solução. O uso do ALM em uma abordagem de otimização híbrida, como proposto neste capítulo (com resultados numéricos analisados na subseção 5.3.1), permitiu melhorar substancialmente a robustez e a qualidade das soluções no problema de eficiência energética em cenários mais desafiadores quando comparado ao PSO e PSO-GSA.

**Tabela 14: Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO.**

Us.	250 iter			500 iter			1000 iter		
	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]
32	$5,6858 \times 10^{+11}$	0	2,4383	$5,6860 \times 10^{+11}$	0	4,8361	$5,6860 \times 10^{+11}$	0	9,3129
64	$4,9820 \times 10^{+11}$	0	3,1103	$4,9827 \times 10^{+11}$	0	6,5712	$4,9831 \times 10^{+11}$	0	13,5098
128	$4,8402 \times 10^{+11}$	7,3605	4,9147	$4,8426 \times 10^{+11}$	5,9039	11,7972	$4,8468 \times 10^{+11}$	1,8124	18,3517
256	$4,6076 \times 10^{+11}$	72,7931	11,5767	$4,6113 \times 10^{+11}$	31,1302	22,6672	$4,6056 \times 10^{+11}$	14,5482	45,5873

**Tabela 15: Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO.**

Us.	2000 iter			3000 iter		
	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]
32	$5,6860 \times 10^{+11}$	0	17,6053	$5,6860 \times 10^{+11}$	0	27,1464
64	$4,9835 \times 10^{+11}$	0	26,9322	$4,9836 \times 10^{+11}$	0	38,4339
128	$4,8420 \times 10^{+11}$	0,9574	36,8446	$4,8589 \times 10^{+11}$	0,7904	57,7514
256	$4,6118 \times 10^{+11}$	13,6053	97,0047	$4,6083 \times 10^{+11}$	12,4291	140,8169

**Tabela 16: Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO-GSA.**

Us.	250 iter			500 iter			1000 iter		
	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]
32	$5,6860 \times 10^{+11}$	0	5,8698	$5,6860 \times 10^{+11}$	0	11,5302	$5,6860 \times 10^{+11}$	0	23,1262
64	$4,9294 \times 10^{+11}$	0	16,0323	$4,9835 \times 10^{+11}$	0	33,0038	$4,9838 \times 10^{+11}$	0	63,2914
128	$4,6447 \times 10^{+11}$	14,8371	121,1443	$4,7918 \times 10^{+11}$	12,1397	235,6827	$4,8629 \times 10^{+11}$	12,4294	504,7628
256	$4,1975 \times 10^{+11}$	28,1355	231,5806	$4,3334 \times 10^{+11}$	31,3355	503,7841	$4,5394 \times 10^{+11}$	58,9356	924,2613

**Tabela 17: Tempo de execução, valor EE atingível e factibilidade para o algoritmo PSO-GSA.**

Us.	2000 iter			3000 iter		
	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]	$J(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	$\mathcal{F}$	Tempo[s]
32	$5,6860 \times 10^{+11}$	0	50,5295	$5,6860 \times 10^{+11}$	0	70,5422
64	$4,9838 \times 10^{+11}$	0	129,5030	$4,9838 \times 10^{+11}$	0	194,8184
128	$4,8485 \times 10^{+11}$	0,1971	929,1938	$4,8623 \times 10^{+11}$	0,1294	1396,8962
256	$4,6305 \times 10^{+11}$	71,7410	1775,1679	$4,6305 \times 10^{+11}$	69,7411	2848,1634

O método híbrido ALPSO descrito em (SEDLACZEK; EBERHARD, 2006), apresenta bom desempenho para problemas gerais de PNL (KHOUKHI et al., 2011) (SAFARI et al., 2013). ALPSO utiliza o método Heurístico PSO na resolução do subproblema (73) de ALM no qual considera a geração do enxame inicial no conjunto  $p_{\min} \leq p_i \leq p_{\max}$ .

**Tabela 18: Tempo de execução, valor EE atingível, número de iterações para convergência, factibilidade e optimalidade para os algoritmos EE-OCDMA, considerando o aumento do número de nós ópticos**

Método	Tempo[s]	FuncCont	FLOPS	$J_2(\mathbf{p}) \left[ \frac{\text{bit}}{\text{Joule}} \right]$	Iter.	$\mathcal{F}$	Optimalidade
<b>32 usuários</b>							
ALPSO	6,250663	109750	$2,0345 \times 10^{+8}$	$5,6860 \times 10^{+11}$	6	0	0,0846
<b>64 usuários</b>							
ALPSO	88,993553	1477954	$9,5701 \times 10^{+9}$	$4,9829 \times 10^{+11}$	50	0	0,0907
<b>128 usuários</b>							
ALPSO	147,053809	1783754	$6,0758 \times 10^{+10}$	$4,8483 \times 10^{+11}$	50	0	0,0944
<b>256 usuários</b>							
ALPSO	337,766946	3567354	$5,4381 \times 10^{+11}$	$4,5710 \times 10^{+11}$	50	0	0,0937

Analisando o comportamento do ALPSO no problema EE, destacado na Tabela 18 pode-se notar que o método deixou de ser eficiente quando consideramos redes com 64, 128 e 256 usuários. O método não atingiu a convergência com o máximo estipulado de 50 iterações externas. A estratégia da hibridação do ALM com um método heurístico-evolucionário para a solução do problema de otimização EE-OCDMA deve-se aproximar do comportamento do ALM, o qual resolve cada subproblema utilizando como ponto inicial a solução do subproblema anterior. Assim, foram avaliadas as hibridações em que o enxame é criado em uma vizinhança relativa à melhor aproximação atual.

## 5.4 CONCLUSÕES DO CAPÍTULO

Os resultados numéricos obtidos mostraram que o método híbrido ALM-PSO resulta em um método robusto e rápido e, a estratégia baseada no método Lagrangiano aumentado pode adaptar-se as especificidades do problema de EE. O método híbrido apresenta resultados convincentes sobre as propriedades de convergência e robustez ao lidar com as restrições do problema sem a necessidade de parâmetros de penalidades. Por outro lado, o ALM-PSOGSA e o ALM-BFGS se mostraram competitivos apenas para redes menores. Vale a pena notar que os métodos de otimização híbrida aqui analisados para o contexto do problema EE-OCDMA podem ser facilmente adaptados a problemas gerais não lineares da rede de alocação de recursos.

## 6 OTIMIZAÇÃO DO COMPROMISSO EFICIÊNCIA ENERGÉTICA E EFICIÊNCIA ESPECTRAL EM REDES OCDMA

Este capítulo apresenta duas técnicas de escalarização para resolução do problema do compromisso entre eficiência energética e espectral (EE-SE) apresentado no Capítulo 2, Seção 2.2 (ALIANO, 2016), (EHRGOTT; RUZIKA, 2008). São descritas as principais características de cada abordagem (de pesos e de  $\epsilon$ -restrito), sendo a métrica de pesos comumente aplicada ao problema EE-SE (ZUO et al., 2018). Por outro lado, a técnica do  $\epsilon$ -restrito, que não utiliza constantes de ponderação, é menos explorada para o problema. Sendo assim, as características do problema EE-SE foram analisadas tendo em vista justificar o uso destas técnicas, e os resultados numéricos referentes à comparação desses métodos foram apresentados. Adicionalmente, neste capítulo foram abordados métodos de programação não linear como estratégias associadas às técnicas de escalarização na resolução do problema do compromisso EE-SE.

O problema de alocação de recursos em termos de otimização do compromisso EE-SE apresentado na Seção 2.2 é formulado com o objetivo de maximizar o EE-SE simultaneamente:

$$\begin{aligned} \max_{\mathbf{p}} \eta_{SE} \left[ \frac{\text{bit}}{\text{s.Hz}} \right] \quad \text{e} \quad \max_{\mathbf{p}} \eta_{EE} \left[ \frac{\text{bit}}{\text{J}} \right] & \quad (91) \\ \text{s. t. (C.1)} \quad p_{\min} \leq p_i \leq p_{\max} & \\ \text{(C.2)} \quad \gamma_i \geq \gamma_i^*, \forall i & \\ \text{(C.3)} \quad r_i \geq r_{i,\min}^{\text{serv}} & \end{aligned}$$

$\mathbf{p} = [p_1, p_2, \dots, p_K]$  é o vetor de potência alocada considerando  $K$  nós ópticos, e  $\gamma_i$  é a SINR para o  $i$ -ésimo usuário, dado por (14).

## 6.1 RESOLUÇÃO DO PROBLEMA MULTIOBJETIVO DO COMPROMISSO EE $\times$ SE

Em MOO, geralmente os problemas abordados envolvem funções de mérito conflitantes, e sua otimização simultânea fornece um conjunto de alternativas que refletem diferentes compromissos entre os critérios considerados. Como a obtenção de um conjunto completo e preciso de soluções é uma tarefa difícil, e especialmente custosa do ponto de vista prático, um conjunto finito e limitado de alternativas, que trazem as melhores soluções ótimas globais, é frequentemente determinado.

Os métodos para resolver um MOO geralmente focam em três metas importantes:

- a) obter um conjunto de soluções que esteja o mais próximo possível da fronteira de Pareto;
- b) obter um conjunto de soluções com a maior diversidade possível, incluindo critérios como uniformidade no espalhamento ao longo da fronteira de Pareto;
- c) alcançar as duas metas anteriores com a maior eficiência computacional possível.

Nesta seção, duas técnicas de escalarização para otimização multiobjetivo são analisadas para resolver o problema do compromisso EE-SE em redes OCDMA: o método WS e o método  $\epsilon$ -restrito. Ambas estratégias são combinados com métodos de PNLs, tais como, o ALM e o método SQP (NOCEDAL; WRIGHT, 2006).

### 6.1.1 MÉTODO DA SOMA PONDERADA

Segundo (ALIANO, 2016), o método WS escala o conjunto das funções-objetivos do problema multiobjetivo original e o transforma em um problema mono-objetivo ponderado. Para que este resultado seja obtido, deve-se considerar uma combinação convexa de cada função-objetivo considerada, sendo  $\lambda_k$  o peso para cada uma delas, que variado, permitirá a geração de outras soluções eficientes distintas.

Pode-se destacar a importância em mensurar adequadamente os pesos para cada objetivo. Isso significa que, quanto mais (menos) importante for aquele critério no problema, maior (menor) deve ser o valor do peso  $\lambda_k$  associado ao objetivo. Atribuir estes pesos requer uma tarefa adicional de não permitir que a magnitude de cada função-objetivo não afete a geração de soluções eficientes.

Após normalizá-las, uma composição dos objetivos  $z_w$  é formada e temos um MOO transformado em uma sequência de subproblemas de otimização mono-objetivo, como a seguir:

$$\begin{aligned} \min_{\mathbf{x}} \quad & \sum_{k=1}^r \lambda_k f_k(\mathbf{x}) \\ \text{s. t.} \quad & \mathbf{x} \in \mathcal{X}, \end{aligned} \quad (92)$$

sendo considerado sem perda de generalidade  $\sum_{k=1}^r \lambda_k = 1$  e  $\lambda_k \in [0, 1]$ . Assumimos que as funções  $f_k(x)$  já estejam normalizadas.

Para aplicar esta técnica ao problema de RE em OCDMA (compromisso EE-SE), podemos redefinir a métrica RE em (20) da seguinte maneira:

$$\eta_{RE} = (1 - \lambda) \eta_{EE} + \lambda \cdot r_c \frac{\eta_{SE}}{\iota K p_{\max} + P_C}, \quad (93)$$

$p_{\max}$  é a potência óptica máxima disponível para a transmissão,  $P_C$  é a potência de circuitaria,  $\lambda$  o fator de ponderação entre  $\eta_{EE}$  e  $\eta_{SE}$  com respeito à capacidade e potência consumida. Definida como em (93) a métrica é fisicamente consistente, como analisado na Subseção 2.2.3.

Deste modo, o problema MOO relacionado à métrica (20) pode ser descrito imediatamente pelo método da soma ponderada:

$$\begin{aligned} \max_{\mathbf{p} \in \mathbb{R}^K} \quad & \eta_{RE} = (1 - \lambda) \eta_{EE} + \lambda \cdot r_c \frac{\eta_{SE}}{\iota K p_{\max} + P_C} \quad [\text{bit/J}] \\ \text{s. t.} \quad & \text{(C.1)} \quad p_{\min} \leq p_i \leq p_{\max} \\ & \text{(C.2)} \quad \gamma_i \geq \gamma_i^*, \forall i \\ & \text{(C.3)} \quad r_i \geq r_{i,\min}^{\text{serv}} \end{aligned} \quad (94)$$

sendo  $\lambda \in [0, 1]$ ,  $p_i^{\max}$  é a potência máxima do laser disponível para o  $i$ -ésimo usuário, e  $\gamma_i$  a SINR do  $i$ -ésimo usuário é dada por (14). Observe que, como a unidade para EE é bits/Joule e a unidade para SE é bits/s.Hz, não é apropriado adicionar diretamente o EE e SE devido à inconsistência da unidade métrica. Uma vez que a largura de banda  $W \approx r_c$  em sistemas ópticos é numericamente maior que a potência de transmissão total consumida,  $P_T$ , um simples somatório de EE e SE tenderá a privilegiar o problema de otimização no EE em detrimento da SE. Isso distorcerá o objetivo de equilíbrio entre EE e SE. Desta forma, dividimos  $\eta_{SE}$  por  $\iota K p_{\max} + P_C$  para que as possíveis combinações de EE e SE a serem maximizadas possuam a mesma ordem de grandeza, como observado na Subseção 2.2.3.

Na sequência, o Teorema 2 relaciona soluções globais de (94) com a fronteira de



Pareto do problema (91).

**Teorema 2** *Uma solução global para o problema definido em (94) é uma solução de Pareto para o problema MOO original.*

**Demonstração:** Seja  $\mathbf{p}_\lambda^* \in \wp$ , o conjunto  $\wp$  é definido em (95)

$$\wp \subseteq R^K = \{p_i \mid p_{\min} \leq \mathbf{p}_i \leq p_{\max}; \gamma \geq \gamma_i^*; r_i \geq r_{i,\min}^{serv}, \forall i\}. \quad (95)$$

Considerando que as funções que compõem o problema (94) são continuamente diferenciáveis,  $\mathbf{p}_\lambda^*$  uma solução global do problema e  $\lambda \in [0, 1]$ . Se  $\mathbf{p}_\lambda^*$  não está na fronteira de Pareto, como  $\eta_{EE}$  é um problema fracional,  $\eta_{SE}$  é um problema côncavo e ambos objetivos não são negativos em  $\wp$ , logo existe uma solução global  $\bar{\mathbf{p}}_\lambda \in \wp$  de modo que

$$\eta_{EE}(\bar{\mathbf{p}}_\lambda) > \eta_{EE}(\mathbf{p}_\lambda^*)$$

e

$$\frac{\eta_{SE}(\bar{\mathbf{p}}_\lambda)}{\iota K p_{\max} + P_c} > \frac{\eta_{SE}(\mathbf{p}_\lambda^*)}{\iota K p_{\max} + P_c}$$

então

$$(1 - \lambda)\eta_{EE}(\bar{\mathbf{p}})_\lambda > (1 - \lambda)\eta_{EE}(\mathbf{p}_\lambda^*)$$

e

$$\lambda\eta_{SE}(\bar{\mathbf{p}})_\lambda > \lambda\eta_{SE}(\mathbf{p}_\lambda^*),$$

o que contradiz que  $\mathbf{p}_\lambda^*$  ser uma solução global de (94). Logo  $\mathbf{p}_\lambda^*$  é uma solução de Pareto do MOO original.

□

Assim, o método WS proposto para resolver o problema de otimização do RE-OCDMA pode ser resumido no Algoritmo 10. Observe que, devido à simplicidade da formulação combinada com os resultados adequados para o compromisso entre EE-SE em redes sem fio, conforme relatado em (SONG et al., 2018) e (AMIN et al., 2016), os métodos WS tornam-se uma opção a ser comparada. Como desvantagem, o método WS geralmente repete soluções multi-objetivas, conforme discutido em (TANG et al., 2019), (ZUO et al., 2018) e (AMIN et al., 2016).

**Algoritmo 10:** WS-RE – Soma ponderada para a otimização de RE-OCDMA

```

1 Escolha:  $\delta \in (0, 1)$ , aleatoriamente  $\mathbf{p}^0$  na caixa  $p_{\min} \leq p_1 \leq p_{\max}$ ;
2 Defina:  $\lambda = 0$  e  $k = 0$ ;
3 repita
4   Resolva o problema (94) com ALM ou SQP;
5    $\lambda \leftarrow \lambda + \delta$ ;
6    $k = k + 1$ ;
7    $\mathbf{p}_\lambda^* = \mathbf{p}^k$ .
8 até  $\lambda > 1$ ;
```

### 6.1.2 MÉTODO $\epsilon$ -RESTRITO

Além do método da soma de peso, existem outras formas de abordar um MOO. Dentre os métodos conhecidos na literatura para resolver problemas de MOO como em (21) encontra-se o método  $\epsilon$ -restrito (HAIMES et al., 1971). A ideia central deste método é que um dos objetivos é escolhido como o único objetivo a ser otimizado, com os demais sendo tratados como restrições de desigualdade do problema, permitindo que os métodos clássicos de otimização mono-objetivo possam ser aplicados.

De modo a superar as dificuldades do método WS, principalmente para problemas MOO com fronteira de Pareto não convexa, a técnica  $\epsilon$ -C apresenta-se como uma alternativa (ALIANO, 2016). Dessa forma, o problema RE apresentado em (93) pode ser reformulado da seguinte forma:

$$\max_{\mathbf{p} \in \mathbb{R}^K} \eta_{EE} = r_c \frac{\eta_{SE}}{P_T} = \frac{\sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i)}{t \sum_i^K p_i + P_C} \left[ \frac{\text{bit}}{\text{Joule}} \right], \quad (96)$$

$$\text{s. t. (C.1)} \quad p_{\min} \leq p_i \leq p_{\max}$$

$$(C.2) \quad \gamma_i \geq \gamma_i^*, \forall i$$

$$(C.3) \quad r_i \geq r_{i,\min}^{\text{serv}}$$

$$(C.\epsilon) \quad \frac{1}{r_c} \sum_{i=1}^K w_i \log_2(1 + \theta_i \gamma_i) \geq \epsilon$$

$\epsilon \in [\eta_{SE}(\bar{\mathbf{p}}), \max \eta_{SE}]$ . O intervalo de  $\epsilon$  é um limitante inferior da restrição (C. $\epsilon$ ) do método  $\epsilon$ -C e determinado pelos valores que  $\eta_{SE}$  podem assumir na fronteira de Pareto. O valor máximo de  $\eta_{SE}$  pode ser determinado resolvendo o problema (94) considerando  $\lambda = 1$ . Por outro lado, o valor mínimo  $\eta_{SE}(\bar{\mathbf{p}})$  é determinado obtendo  $\bar{\mathbf{p}}$  solução do problema (94) considerando  $\lambda = 0$ . Essa escolha para o valor mínimo é feita porque qualquer outro vetor

$\mathbf{p}$  cujo valor de  $\eta_{SE}$  seja menor que esse também terá um valor menor de  $\eta_{EE}$ ; portanto, esse vetor será dominado pelo vetor solução  $\bar{\mathbf{p}}$ , conseqüentemente, não seria uma solução de Pareto. Portanto,  $\epsilon \in [\eta_{SE}(\bar{\mathbf{p}}), \max \eta_{SE}]$  em que  $\bar{\mathbf{p}}$  indica o ponto de solução do problema (60).

Na seqüência, o Teorema 3 apresenta a condição necessária e suficiente para que soluções globais de (96) estejam na fronteira de Pareto do problema (91).

**Teorema 3** *Uma solução global para o problema definido em (96) é uma solução na fronteira de Pareto para o problema se, e somente se, for igual:*

$$\sum_{i=1}^K \frac{1}{r_c} w_i \log_2(1 + \theta_i \gamma_i) = \epsilon \quad (97)$$

na solução.

**Demonstração:** Seja  $\mathbf{p}_\epsilon^* \in \wp$ ,  $\wp$  definido em (95). ( $\Rightarrow$ ) Seja  $\mathbf{p}_\epsilon^*$  um ponto sobre a fronteira de Pareto, devemos mostrar que esse vetor é a solução do problema (96) para alguma escolha de  $\epsilon$ . Supondo que  $\mathbf{p}_\epsilon^*$  não seja uma solução global do problema com  $\epsilon = \eta_{SE}(\mathbf{p}_\epsilon^*)$ . Então existe uma solução global  $\bar{\mathbf{p}}_\epsilon$  para este problema, assim

$$\eta_{EE}(\bar{\mathbf{p}}_\epsilon) > \eta_{EE}(\mathbf{p}_\epsilon^*),$$

$$\eta_{SE}(\bar{\mathbf{p}}_\epsilon) \geq \eta_{SE}(\mathbf{p}_\epsilon^*)$$

o que, por sua vez, contradiz que  $\mathbf{p}_\epsilon^*$  esta na fronteira de Pareto. Assim  $\mathbf{p}_\epsilon^*$  é solução global do problema (96) com  $\epsilon = \eta_{SE}(\mathbf{p}_\epsilon^*)$ , conseqüentemente  $\mathbf{p}_\epsilon^*$  satisfaz a igualdade.

( $\Leftarrow$ ) Se  $\mathbf{p}_\epsilon^*$  é solução global do problema (96), e vale

$$\epsilon = \eta_{SE}(\mathbf{p}_\epsilon^*),$$

então, não há outra solução  $\bar{\mathbf{p}}_\epsilon$  de modo que  $\eta_{EE}(\bar{\mathbf{p}}_\epsilon) \geq \eta_{EE}(\mathbf{p}_\epsilon^*)$  e  $\eta_{SE}(\bar{\mathbf{p}}_\epsilon) \geq \eta_{SE}(\mathbf{p}_\epsilon^*)$ , assim  $\mathbf{p}_\epsilon^*$  está na fronteira de Pareto.

□

A equação (97) no Teorema 3, indica que a restrição de desigualdade (C. $\epsilon$ ), do problema (96), é satisfeita como uma igualdade em uma solução pertencente à fronteira de Pareto.

O método  $\epsilon$ -C está resumido no Algoritmo 11. Uma dificuldade na aplicação do método  $\epsilon$ -C consiste no fato de qualquer solução de Pareto encontrada pelo método deve satisfazer a desigualdade de restrição ( $C.\epsilon$ ) como uma igualdade.

**Algoritmo 11:**  $\epsilon$ -C-RE –  $\epsilon$ -Restrito para otimização de RE-OCDMA

- 1 **Escolha:**  $\delta \in (0, 1)$ , aleatoriamente  $\mathbf{p}^0$  na caixa  $p_{\min} \leq p_i \leq p_{\max}$ ;
- 2 **Calcule:**  $\bar{\mathbf{p}}$  solução de (60) e  $\max \eta_{SE}$ ;
- 3 **Defina:**  $\epsilon = \delta(\max \eta_{SE} - \eta_{SE}(\bar{\mathbf{p}}))$ ;
- 4 **repita**
- 5     Resolva o problema (96) aplicando ALM ou SQP;
- 6      $\epsilon \leftarrow \epsilon + \delta(\max \eta_{SE} - \eta_{SE}(\bar{\mathbf{p}}))$ ;
- 7      $\mathbf{p}_\epsilon^* = \mathbf{p}^k$ ;
- 8      $k = k + 1$ .
- 9 **até**  $\epsilon \geq \max \eta_{SE}$ ;

O método WS trabalha diretamente com a RE,  $\lambda$  define um peso entre  $\eta_{EE}$  e  $\eta_{SE}$ . Não há correspondência *a priori* entre  $\lambda$  e um vetor de solução, e cabe ao tomador de decisão escolher pesos apropriados. Uma desvantagem do método WS é que pesos diferentes podem implicar em soluções iguais. Diferentemente do método WS, o método  $\epsilon$ -C não considera diretamente a RE no seu objetivo, porém ao estipular valores adequados para  $\epsilon$  estamos definindo o peso exato que  $\eta_{SE}$  terá em RE, assim otimizando o problema (96) também obtemos soluções para RE. Uma motivação para o uso do método  $\epsilon$ -C é que valores diferentes para  $\epsilon$  implicam em soluções diferentes.

### 6.1.3 MÉTODO DO LAGRANGEANO AUMENTADO

O método de otimização do ALM procura resolver um PNL restrito, resolvendo uma sequência mais simples de problemas, como apresentado no Capítulo 3. Cada um desses problemas possui apenas algumas restrições simples. Tais restrições definem uma caixa; no nosso caso, descrito por

$$\Omega = \{\mathbf{p} \in \mathbb{R}^K \mid p_{\min} \leq p_i \leq p_{\max}\},$$

em que a função de custo é maximizada com a função Lagrangiana aumentada aplicando o subproblema do método WS ou implementando alternativamente o subproblema do método  $\epsilon$ -C.

O problema de RE-OCDMA em (94) ou, alternativamente, o problema de EE-

OCDMA em (96) pode ser visto como um problema PNL, da seguinte maneira:

$$\begin{aligned} & \underset{\mathbf{p} \in \mathbb{R}^K}{\text{maximize}} && f(\mathbf{p}) \\ & \text{s. t.} && p_{\min} \leq p_i \leq p_{\max}, \quad \forall i = 1, \dots, K \\ & && \mathbf{g}(\mathbf{p}) \geq 0. \end{aligned} \tag{98}$$

Portanto, considerando o problema original RE-OCDMA em (94), aqui  $f(\cdot)$  representa a função de eficiência de recursos  $\eta_{RE}$ , enquanto  $\mathbf{g}(\cdot)$  representa as restrições definidas em (C.2) e (C.3). Analogamente, ao considerar o problema EE-OCDMA em (96),  $f(\cdot)$  representa  $\eta_{EE}$  e a função de  $\mathbf{g}(\cdot)$  representa as restrições (C.2), (C.3) e (C.ε). Portanto, com opções adequadas para  $f(\cdot)$  e  $\mathbf{g}(\cdot)$ , a função Lagrangiana pode ser definida como:

$$\mathcal{A}_\rho(\mathbf{p}, \boldsymbol{\mu}) = f(\mathbf{p}) + \frac{\rho}{2} \sum_{i=1}^m \left[ [\mathbf{g}_i(\mathbf{p})]^+ + \frac{\mu_i}{\rho} \right]^2, \tag{99}$$

$f(\mathbf{p}) : \mathbb{R}^K \rightarrow \mathbb{R}$ , as funções  $\mathbf{g}(\mathbf{p})$ , devem apresentar as primeiras derivadas contínuas em  $\mathbb{R}^K$ ,  $[\alpha]^+ = \max[0, \alpha]$ ; o parâmetro de penalidade  $\rho > 0$  e  $\mu_i \geq 0$  são aproximações para os multiplicadores de Lagrange. Uma análise mais detalhada do ALM pode ser encontrada em (PENDEZA MARTINEZ et al., 2019) e (MARTINEZ et al., 2020). O Algoritmo 12 apresenta um pseudocódigo para o ALM aplicado ao problema do RE-OCDMA.

**Algoritmo 12:** ALM-RE – Lagrangiano aumentado para otimização de RE-OCDMA

- 1 Parâmetros de entrada:  $\mathbf{p}^0$ , precisão  $\zeta > 0$ ,  $\mu_{\max} > 0$ ,  
 $\mu_i^1 \in [0, \mu_{\max}]$ ,  $\forall i = 1, \dots, m$ ,  $\tau \in [0, 1)$   $\{\varepsilon_k\} \subset \mathbb{R}_+$  de modo a  $\lim_{k \rightarrow \infty} \varepsilon_k = 0$ ,  
 $\rho \in (0, \rho_{\max}]$ ;
- 2  $k = 0$ ;
- 3 **repita**
- 4     Calcule  $\mathbf{p}^k \in \mathbb{R}^K$  satisfazendo
 
$$\left\| \mathcal{P}(\mathbf{p}^k - \nabla \mathcal{A}(\mathbf{p}^k, \boldsymbol{\mu}^k)) - \mathbf{p}^k \right\| \leq \varepsilon_k, \tag{100}$$
- 5     Atualize os multiplicadores:  
 $\mu_i^{k+1} = \max\{0, \mu_i^k + \rho_k g_i(\mathbf{p}^k)\}$ ,  $i = 1, \dots, m$  e  $\mu_i^{k+1} \in [0, \mu_{\max}]$ ;
- 6     Atualize o parâmetro de penalidade:  
 $V_i^k = \max \left\{ g_i(\mathbf{p}^k), -\frac{\mu_i^k}{\rho_k} \right\}$ , onde  $\rho_{k+1} =$   
 $\begin{cases} \rho_k, & \text{if } \|V^k\|_\infty \leq \tau \|V^{k-1}\|_\infty \\ \nu \cdot \rho_k, & \text{Caso contrário, com } \nu > 1 \end{cases}$ ;
- 7      $k \leftarrow k + 1$ ;
- 8 **até**  $\|\mathbf{p}^k - \mathbf{p}^{k-1}\| \leq \zeta$ ;
- 9 Saída:  $\mathbf{p}^* = \mathbf{p}^k$

### 6.1.4 PROGRAMAÇÃO QUADRÁTICA SEQUENCIAL

O objetivo do método de programação quadrática sequencial é determinar a solução de (98) como o limite para as soluções de uma seqüência de problemas quadráticos. No nosso problema de otimização RE-OCDMA, a função  $f(\mathbf{p})$  em (98) é substituída por uma aproximação quadrática da função Lagrangiana  $\mathcal{L}$ , definida por:

$$\mathcal{L}(\mathbf{p}, \boldsymbol{\mu}) = f(\mathbf{p}) + \sum_{i=1}^m \mu_i [-g_i(\mathbf{p})], \quad (101)$$

sendo as restrições não lineares substituídas por aproximações lineares das mesmas. Assim, cada iteração  $k$  do método SQP resolve o seguinte problema de programação quadrática:

$$\begin{aligned} \underset{\mathbf{d} \in \mathbb{R}^K}{\text{maximize}} \quad & f(\mathbf{p}^k) + \nabla f(\mathbf{p}^k)^\top \mathbf{d} + \frac{1}{2} \mathbf{d}^\top \nabla^2 \mathcal{L}(\mathbf{p}^k) \mathbf{d} \\ \text{s.t.} \quad & -\nabla g_i(\mathbf{p}^k)^\top \mathbf{d} - g_i(\mathbf{p}^k) \geq 0, \quad \forall i, \end{aligned} \quad (102)$$

com o objetivo de determinar a melhor direção de busca, denotada por  $\mathbf{d}^k$  (a partir do ponto  $\mathbf{p}^k$ ) como a solução de (102) e associada aos multiplicadores de Lagrange  $\boldsymbol{\mu}^k$  na  $k$ -ésima iteração. A atualização para o próximo ponto  $\mathbf{p}^{k+1}$  é obtida projetando  $\mathbf{p}^k + a_k \mathbf{d}^k$  na caixa  $p_{\min} \leq p_i \leq p_{\max}$ ,  $a_k \in (0, 1]$  é determinado para garantir as propriedades de convergência do método. Uma análise mais detalhada sobre o método SQP aplicado ao problema pode ser encontrada em (NOCEDAL; WRIGHT, 2006). O Algoritmo 13 descreve o pseudocódigo para o método SQP para o problema RE-OCDMA.

**Algoritmo 13:** SQP-RE – Programação quadrática sequencial para otimização de RE-OCDMA

- 1 Escolha um ponto inicial  $(\mathbf{p}^0, \boldsymbol{\mu}_0)$  e tolerância  $\zeta > 0$ ;
- 2  $k = 0$ ;
- 3 **repita**
- 4     Avalie  $f(\mathbf{p}^k)$ ,  $\nabla f(\mathbf{p}^k)$ ,  $\nabla^2 \mathcal{L}(\mathbf{p}^k)$ ,  $g(\mathbf{p}^k)$  e  $\nabla g(\mathbf{p}^k)$ ;
- 5     Resolva (102) para obter  $\mathbf{d}^k$  e  $\boldsymbol{\mu}^{k+1}$ ;
- 6      $\mathbf{p}^{k+1} \leftarrow \mathcal{P}(\mathbf{p}^k + a_k \mathbf{d}^k)$ ;
- 7     onde  $\mathcal{P}$  é o operador projeção ortogonal na caixa  $p_{\min} \leq p_i \leq p_{\max}$ ;
- 8      $\mathbf{p}^* = \mathbf{p}^k$
- 9 **até**  $\|\mathbf{p}^k - \mathbf{p}^{k-1}\| \leq \zeta$ ;
- 10 Saída:  $\mathbf{p}^* = \mathbf{p}^k$

## 6.2 DETALHES DE IMPLEMENTAÇÃO

Esta seção discute os aspectos relevantes a respeito da implementação dos métodos de escalarização aplicados ao problema do compromisso EE-SE. Os aspectos de implementação dos algoritmos de otimização levam em conta topologias de redes ópticas realísticas, sendo a arquitetura de rede OCDMA usada assim como em (WONG, 2012) e (DURAND; ABRAO, 2017) e a mesma utilizada no Capítulo 4.

Para resolver os problemas de otimização (94) e (96), respectivamente, o ALM e, alternativamente, os métodos SQP foram aplicados em conjunto com as abordagens WS e  $\epsilon$ -C.

O Algoritmo ALM foi inicializado com os multiplicadores iniciais nulos e parâmetro de penalidade  $\rho_0 = 10$ . O ponto inicial do vetor de potência foi inicializado como uma aproximação para o vetor  $\mathbf{p}$ , com  $p_i \in [p_{\min}, p_{\max}]$ ,  $i = 1, \dots, K$ . Como os multiplicadores iniciais são nulos, o peso da função objetivo e o peso da infactibilidade são iguais na função objetivo do primeiro subproblema. Para resolver o subproblema, é utilizado o método BFGS apresentado na Seção 5.

O Método SQP utiliza a função *fmincon* do Matlab como descrito no Capítulo 4. No método o ponto inicial do vetor de potência foi inicializado como uma variável aleatória com distribuição uniforme no intervalo  $p_i \in [p_{\min}, p_{\max}]$ . O cálculo do gradiente foi implementado por diferenças finitas, enquanto o subproblema quadrático foi resolvido usando um método dos pontos interiores (NOCEDAL; WRIGHT, 2006) aplicado a subprogramas quadráticos convexos.

Para os métodos ALM e SQP, a seguinte condição foi considerada como critério de parada.

$$\zeta = \|\mathbf{p}^k - \mathbf{p}^{k-1}\| < 10^{-6}, \quad \text{com } \mathbf{p}^k \text{ um ponto factível.}$$

**ALM  $\times$  SQP sub-passos:** A escolha dos métodos ALM e SQP para fins de comparação deve-se à simplicidade de definição e às boas propriedades teóricas de ambos os métodos, especificamente para problemas envolvendo programação não linear, resultando nos métodos de otimização multiobjetivos WS e  $\epsilon$ -C. Esses métodos exigem a solução de uma sequência de problemas de PNL mais simples que o original. Considerando a resolução sequencial dos problemas (94) e (96) para WS e  $\epsilon$ -C respectivamente, aplicamos o ALM, de modo que o primeiro problema use, como mencionado anteriormente, o ponto de partida aleatório e multiplicadores nulos utilizados para  $\lambda = 0$  em WS e para calcular  $\bar{\mathbf{p}}$  em  $\epsilon$ -C. Para os

outros subproblemas sequenciais, o ponto de partida é obtido pela solução do problema anterior, assim como os multiplicadores iniciais e os parâmetros de penalidade são assumidos como multiplicadores e os parâmetros de penalidade obtidos com a solução dos subproblemas anteriores. Para o método SQP, consideramos a mesma estratégia, com exceção da estratégia usada no ALM para o parâmetro de penalidade.

No método  $\epsilon$ -C, como mencionado anteriormente, um desafio é determinar um intervalo apropriado para o parâmetro  $\epsilon$ . Assim, manteve-se a meta  $\eta_{EE}$ , enquanto definiu-se  $\eta_{SE}$  como uma restrição, conforme formulado no problema (96).

Os valores dos parâmetros ALM, SQP, WS e  $\epsilon$ -C adotados nos testes numéricos estão resumidos na Tabela 19. Para melhorar a precisão nos testes numéricos, foram consideradas 12 atribuições diferentes para  $\lambda$  e  $\epsilon$ , de modo a encontrar soluções na fronteira de Pareto.

**Tabela 19: Valores de parâmetros de entrada adotados para os algoritmos RE-OCDMA propostos.**

Método	Valores de parâmetros	Algoritmos
WS:	coeficientes: $\lambda \in \{0, \frac{1}{11}, \frac{2}{11}, \dots, 1\}$	10
$\epsilon$ -C:	$\epsilon \in \left\{ \eta_{SE}(\bar{\mathbf{p}}), \eta_{SE}(\bar{\mathbf{p}}) + \frac{\max(\eta_{SE}) - \eta_{SE}(\bar{\mathbf{p}})}{11}, \dots, \max(\eta_{SE}) \right\}$	11
ALM:	parâmetro de penalidade: $\nu = 10$ ; $\rho = 10$ $\mu_{\max} = 10^6$ ; $\zeta = 10^{-6}$ ; $\tau = 10^{-1}$ ; $\epsilon_k = 10^{-6}$ , $\forall k$	12
SQP:	$\zeta = 10^{-6}$	13

Os testes foram realizados no MatLab 8.0, Windows 10 computador Home Single Language, versão 1703, CPU Intel Core i7-7700HQ a 2.80GHz, 16.00GB de RAM, sistema operacional com 64 bits.

### 6.2.1 ERRO QUADRÁTICO MÉDIO NORMALIZADO

Os Teoremas 2 e 3 fornecem condições para que as soluções obtidas pelos métodos WS e  $\epsilon$ -C estejam na fronteira de Pareto. O Teorema 2 exige a necessidade de determinar soluções globais ao se executar o Algoritmo 10 a fim de obter soluções na fronteira de Pareto. Por outro lado, a aplicação do Teorema 3 para a obtenção de soluções na fronteira de Pareto exige além da determinação de soluções globais no Algoritmo 11, que a restrição (C. $\epsilon$ ) seja satisfeita como uma igualdade.



Como o problema  $\eta_{EE}$  é fracional e a função objetivo de  $\eta_{SE}$  é côncava, além dos bons resultados dos métodos ALM e SQP obtidos nos trabalhos de (PENDEZA MARTINEZ et al., 2019) e (ANDREANI et al., 2007a), pode-se esperar que as soluções globais obtidas pelo método WS sejam soluções eficientes no sentido de Pareto. Por outro lado, apenas o bom desempenho de ALM e SQP nos subproblemas gerados pelo método  $\epsilon$ -C não é suficiente para garantir soluções na fronteira de Pareto. Portanto, para concluir a análise dos dados numéricos dos resultados obtidos pelo método  $\epsilon$ -C, incluímos a análise do NMSE.

Do Teorema 3, pode-se medir a qualidade da solução alcançada através do Algoritmo 11 na  $k$ -ésima iteração, expressando a que distância ( $\epsilon$ ) está de  $\eta_{SE}(\mathbf{p}^*)$ , usando a solução  $\mathbf{p}^*$  determinada na etapa 4 do algoritmo. Essa qualidade da solução é quantificada pelo NMSE quando o equilíbrio é alcançado. A qualidade da solução obtida por um algoritmo de otimização de EE, específico na solução de problemas (96) é definida por (MARQUES et al., 2016):

$$\text{NMSE}_{eq} = \mathbb{E} \left[ \frac{\|\eta_{SE}(\mathbf{p}^*) - \epsilon\|^2}{\|\epsilon\|^2} \right], \quad (103)$$

$\|\cdot\|^2$  denota a distância quadrática Euclidiana e  $\mathbb{E}[\cdot]$  é o operador esperança.

### 6.3 RESULTADOS NUMÉRICOS

Nesta seção abordamos os métodos de escalarização para MOO como estratégias de resolução para o problema compromisso EE-SE apresentado em (91). As redes ópticas avaliadas operam sob QoS e taxa de dados distintas, considerando topologias de redes OCDMA realísticas, com base nos códigos MLEWHPC 2-D. A tabela 20 resume os valores dos parâmetros de sistema adotados nas simulações.

Similarmente aos Capítulos 4 e 5, nesta seção, foi adotada SINR alvo de  $\text{SINR}^* = 20\text{dB}$  e considerados dois cenários com:

Cenário A: o compromisso EE-SE é estabelecido sem restrição de taxa mínima de serviço  $r_{\min}^{\text{serv}}$ ;

Cenário B: o melhor compromisso EE-SE é determinado assumindo restrição sobre a taxa mínima de serviço  $r_{\min}^{\text{serv}}$  para alcançar multi-taxas de transmissão ao longo das três diferentes classes de serviços, definidas por  $BER_3 < BER_2 < BER_1$ , com pelo menos

**Tabela 20: Valores de parâmetros adotados.**

Valores de Parâmetros	
Ordem de modulação	$M = 2$
Ineficiência do Transponder	$\iota = 2,7\text{W/Gbps}$
Ruído Branco std	$\sigma = 0,032\text{dB}$
Constante de Planck	$h = 6,63 \times 10^{-34} \text{ J/Hz}$
Período de Chip	$T_c = 9 \text{ ps}$
Alcance do comprimento	de link [4, 100] km
Max. potência do laser	$P_{\max} = 12 \text{ dBm} = 15,85 \text{ mW}$
Min. potência do laser	$P_{\min} = (P_{\max} - 90) \text{ dBm}$
SINR	$\gamma_i^* = 12\text{dB}$
<b>Cenário A: “serv” = Única Classe</b>	
Número de usuários	$K \in \{8, 16, 32\}$
Min. taxa de usuários	$r_{\min} = 100\text{Mbps}; \quad \text{BER}_{\max} = 10^{-11}$
comprimento da sequência OCDMA	$F_i = \frac{T_b}{T_c} = 121$
<b>Cenário B: “serv” = {Classe 1, Classe 2 e Classe 3}</b>	
Usuários por classe	$K \in \{U^{\text{CLASSE 1}}, U^{\text{CLASSE 2}}, U^{\text{CLASSE 3}}\}$
$U^{\text{CLASSE}} = [8, 16, 32]$	$\{[4; 2; 2], [8; 4; 4], [24; 4; 4]\}$
Comprimento da sequência OCDMA	$F_i = \frac{T_b}{T_c} \in \{1331, 121, 11\}$
Min. taxa de usuários por classe	$r_{\min}^{\text{serv1}} = 10 \text{ Mbps}; \quad \text{BER}_{\max}^{\text{serv1}} = 10^{-10}$
e respectivo	$r_{\min}^{\text{serv2}} = 100 \text{ Mbps}; \quad \text{BER}_{\max}^{\text{serv2}} = 10^{-11}$
Max. BER aceitável	$r_{\min}^{\text{serv3}} = 1000 \text{ Mbps}; \quad \text{BER}_{\max}^{\text{serv3}} = 10^{-12}$

uma ordem de grandeza entre duas classes consecutivas.

### 6.3.1 COMPROMISSO EE-SE SEM RESTRIÇÃO NA TAXA MÍNIMA DE SERVIÇO $R_{\min}^{\text{SERV}}$ (CENÁRIO A)

Aplicamos os métodos WS e  $\epsilon$ -C combinados aos métodos ALM e SQP, denominados métodos WS-ALM, WS-SQP,  $\epsilon$ -C-ALM e  $\epsilon$ -C-SQP, visando à determinação do compromisso EE-SE, ideal em uma rede OCDMA, com parâmetros descritos na Tabela 19. Além disso, comparamos a abordagem proposta com o método de Busca Exaustiva (ES – *Exhaustive search*) disponível na literatura (ZUO et al., 2018). Infelizmente, devido à complexidade não polinomial do método de otimização ES, a análise de desempenho e a comparação envolvendo esse método em termos de obtenção de soluções na fronteira de Pareto não foi possível para todas as classes de usuários.

Usando os parâmetros do sistema e do canal, definidos na Tabela 20, o desempenho dos algoritmos na solução do problema do RE-OCDMA é mostrado na Tabela 21. Figuras de mérito adotadas para avaliar o desempenho do método considerando o aumento do número de nós ópticos,  $K \in \{8, 16, 32\}$  usuários, aumentando a dificuldade (ou complexidade) em obter as melhores soluções multi-objetivas, incluem:

- a) Tempo de execução dos Algoritmos (Tempo);
- b) Número de sucessos de convergência (SC);
- c) Número de soluções distintas na fronteira de Pareto (S-FP);
- d) NMSE: conforme equação (103), a definição da NMSE é aplicada somente para o método  $\epsilon$ -C e suas variações;
- e) Número de avaliação de funções (*FuncCont*).

**Tabela 21:** Tempo de execução, número de sucessos de convergência, número de soluções distintas na fronteira de Pareto, NMSE e número de avaliação de função para os algoritmos EE-SE OCDMA considerando o aumento de nós ópticos no Cenário A.

Método	Tempo [s]	SC	S-FP	FuncCont	NMSE
<b><math>K = 8</math> usuários</b>					
WS-ALM	240,19	12	8	7510232	n.a.
WS-SQP	6,16	12	8	57395	n.a.
$\epsilon$ -C-ALM	6,42	12	<b>12</b>	221440	<b><math>1,2906 \times 10^{-8}</math></b>
$\epsilon$ -C-SQP	<b>4,69</b>	12	<b>12</b>	<b>48912</b>	$1,9371 \times 10^{-8}$
ES	$1,3994 \times 10^{+5}$	12	8	$7,0737 \times 10^{+9}$	n.a.
<b><math>K = 16</math> usuários</b>					
WS-ALM	1312,27	11	11	39954584	n.a.
WS-SQP	<b>9,42</b>	12	8	167573	n.a.
$\epsilon$ -C-ALM	10,60	12	<b>12</b>	374170	<b><math>1,2821 \times 10^{-8}</math></b>
$\epsilon$ -C-SQP	9,68	12	<b>12</b>	<b>18380</b>	$2,3725 \times 10^{-8}$
<b><math>K = 32</math> usuários</b>					
WS-ALM	36,55	12	5	1135008	n.a.
WS-SQP	18,21654	12	8	272524	n.a.
$\epsilon$ -C-ALM	<b>15,36</b>	12	<b>12</b>	522919	$2,1593 \times 10^{-8}$
$\epsilon$ -C-SQP	17,97	12	<b>12</b>	<b>25637</b>	<b><math>9,4622 \times 10^{-9}</math></b>

Pode-se observar que, para o compromisso EE-SE OCDMA, o método WS-ALM gera problemas mais complexos a serem resolvidos pelo ALM em comparação com o método  $\epsilon$ -C-ALM. Além disso, observou-se que, para  $K = 16$  usuários, o método WS-ALM não atingiu convergência em uma das execuções, mas encontrou 11 soluções diferentes na fronteira de Pareto. Por outro lado, para  $K = 8$  e  $K = 32$ , o método WS sempre obtém convergência em todas as execuções e determina, respectivamente, 8 e 5 soluções diferentes na fronteira de Pareto. Mais importante, o método  $\epsilon$ -C-ALM alcançou convergência em todas as execuções e configurações de nós ópticos, para as quais o método obtém soluções

distintas e, conforme esperado pelo Teorema 3, a restrição  $(C.\epsilon)$  do problema (96) é satisfeita como igualdade em todos os casos nos testes realizados, verificando os valores NMSE alcançados. Enfatizamos que os valores NMSE para o método WS não são avaliados, pois sua formulação não considera a restrição  $(C.\epsilon)$ . Para os métodos WS-SQP e  $\epsilon$ -C-SQP, pode-se concluir pelo mesmo comportamento em relação ao sucesso da convergência (SC) e ao número de soluções distintas na fronteira de Pareto (S-FP) em relação às obtidas por WL-ALM e  $\epsilon$ -C-ALM. Especificamente, o WS-SQP levou significativamente menos tempo para alcançar a convergência.

A Figura 31 apresenta a fronteira de Pareto obtida para os dois métodos de MOO considerados na solução do compromisso entre EE-SE-OCDMA. Observe que para os usuários  $K = 8, 16$  e  $32$ , a fronteira de Pareto obtida é proporcional. Para os doze valores no intervalo descrito na Tabela 19, o método WS-ALM termina no mesmo ponto próximo ao último limite de Pareto obtido pelos métodos  $\epsilon$ -C-ALM,  $\epsilon$ -C-SQP e WS-SQP. Note-se também que os métodos WS-ALM e WS-SQP repetiram soluções e, como esperado devido à sua construção, as soluções não são distribuídas uniformemente na curva. Além disso, comparamos o desempenho dos métodos propostos com um método bem estabelecido de Busca Exaustiva (ES) disponível na literatura (ZUO et al., 2018), (SONG et al., 2018). Devido à sua complexidade não polinomial, comparamos o desempenho do ES apenas para  $K = 8$  usuários. De fato, os autores (ZUO et al., 2018) e (SONG et al., 2018) consideram redes menores com  $K = 1$  e  $K = 3$  usuários, respectivamente, não sendo viável o tempo computacional necessário para realizar testes para um número maior de usuários, isto é,  $K = 16$  e  $K = 32$  usuários. A precisão obtida em nossa versão implementada do método ES para o problema do RE-OCDMA para  $K = 8$  foi da ordem de  $1,5 \times 10^{-3}$ . Além disso, as soluções obtidas foram próximas as determinadas pelos métodos WS e  $\epsilon$ -C, o que reforça o bom desempenho dos métodos propostos.

A Figura 32 apresenta uma comparação entre os métodos avaliados em relação ao número de funções calculadas, compostas pela função objetivo e pelas funções que compõem as restrições para cada método de otimização considerado. Como é possível observar, o método ES para  $K = 8$  usuários apresenta um número elevado de cálculo de funções, conforme esperado, devido a sua formulação. Para os demais métodos, podemos notar que as variações combinadas ao método SQP tendem a consumir menor número de avaliações de funções, como esperado devido às suas características.

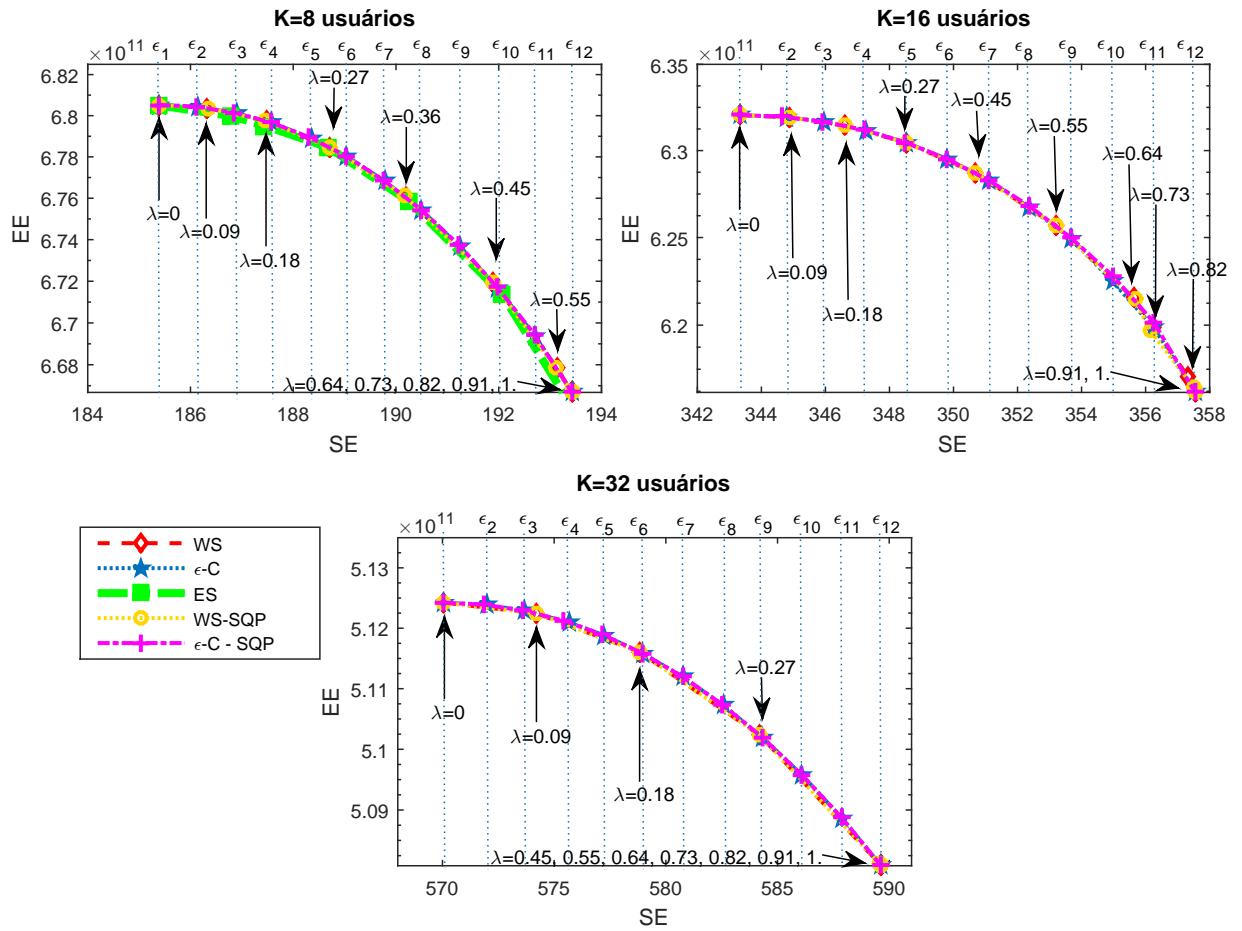
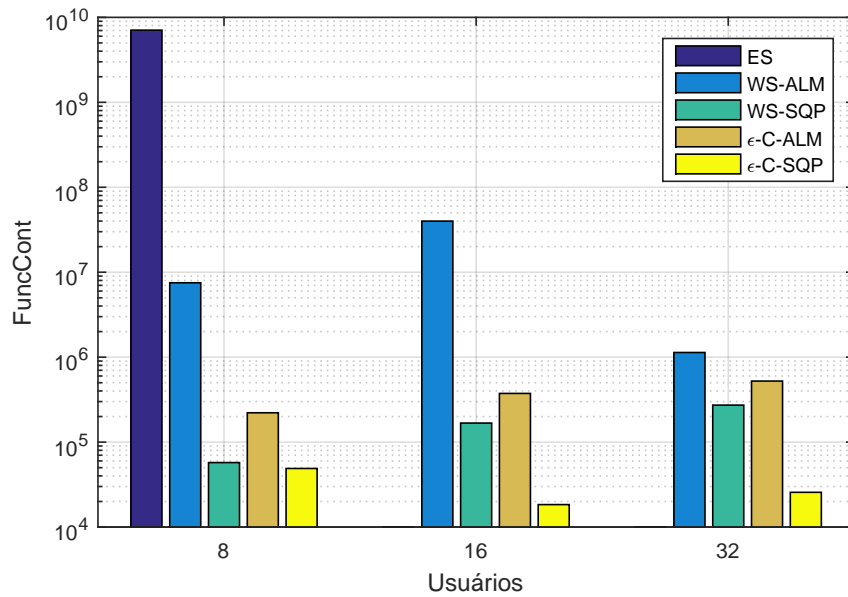


Figura 31: Fronteira de Pareto para o problema EE-SE OCDMA obtida pelos métodos WS e  $\epsilon$ -C para  $K \in \{8; 16; 32\}$  usuários. Fronteira de Pareto obtida pelo método de Busca Exaustiva é representado para o cenário com  $K = 8$  usuários.

Fonte: Autoria própria



**Figura 32:** Evolução do número total de avaliação de funções dos métodos testados para  $K = [8, 16, 32]$  usuários.

Fonte: Autoria própria

### 6.3.2 COMPROMISSO EE-SE COM RESTRIÇÃO NA TAXA MÍNIMA DE SERVIÇO, $R_{\text{MIN}}^{\text{SERV}}$ (CENÁRIO B)

Para o cenário B, os valores dos parâmetros considerados são descritos na Tabela 20 com três classes de serviço e  $K = 8, 16$  e  $32$  usuários. O desempenho dos algoritmos EE-SE-OCDMA é comparado na Tabela 22 em termos de tempo de execução (Tempo), número de sucesso de convergência (SC), número de soluções distintas na fronteira de Pareto (S-FP), número de avaliação de função (FuncCont) e NMSE, para o algoritmo  $\epsilon$ -C, considerando o aumento do número de nós ópticos. Consideramos nos resultados a seguir doze valores distribuídos igualmente para os escalares  $\lambda$  e  $\epsilon$ .

Novamente, o comportamento observado no Cenário A pode ser confirmado para o Cenário B. De fato, observando a Tabela 22, a menos para  $K = 16$  usuários, o método WS-ALM alcança convergência encontrando 4 soluções diferentes na fronteira de Pareto. Para  $K = 8$  e  $K = 32$ , o WS-ALM convergiu em todas as execuções e determinou 8 e 6 soluções diferentes, respectivamente, na fronteira de Pareto. Além disso, o método WS-SQP, para o cenário B, também consumiu o menor tempo computacional para obter convergência em comparação com o WS-ALM. Pode-se destacar que o WS-SQP encontrou 8 soluções diferentes na fronteira de Pareto, para  $K = 8, 16$  e  $32$  usuários, tendo um desempenho superior na obtenção de soluções distintas na fronteira de Pareto em relação

ao método WS-ALM.

Por outro lado, os métodos derivados de  $\epsilon$ -C, isto é,  $\epsilon$ -C-ALM e  $\epsilon$ -C-SQP sob o Cenário B, alcançaram convergência em todas as execuções e foram capazes de encontrar um número absolutamente superior de soluções na fronteira de Pareto. Conforme previsto pelo Teorema 3, a restrição (C. $\epsilon$ ) no problema (96) é satisfeita como igualdade em todos os testes realizados, como verificado pelos valores NMSE atingidos.


Por fim, da mesma maneira que no Cenário A, para  $K = 8$  usuários, o desempenho do método ES na localização de soluções pertencente à fronteira de Pareto foi incluído como referência, uma vez que a busca exaustiva ainda é factível para esta dimensão do problema. Assim, verificou-se que sob essa dimensão do problema, as soluções da fronteira de Pareto encontradas pelos métodos WS-ALM, WS-SQP,  $\epsilon$ -C-ALM e  $\epsilon$ -C-SQP são bastante semelhantes às encontradas pelo método ES, o que reforça o excelente desempenho demonstrado pelos métodos propostos, mesmo em configurações de rede OCDMA com multi-taxas.

**Tabela 22: Figura de mérito adotada para avaliar o desempenho dos algoritmos EE-SE OCDMA considerando o aumento do número de nós ópticos  $K = 8, 16$  e  $32$  usuários multi-taxa no cenário B.**

Método	Tempo [s]	SC	S-FP	FuncCont	NMSE
<b><math>K = 8</math> usuários</b>					
WS-ALM	207,70	12	8	7590533	n.a.
WS-SQP	8,59	12	8	76325	n.a.
$\epsilon$ -C-ALM	6,22	12	<b>12</b>	233892	$2,1509 \times 10^{-8}$
$\epsilon$ -C-SQP	<b>5,23</b>	12	<b>12</b>	<b>68657</b>	<b><math>1,9352 \times 10^{-8}</math></b>
ES	$1,7512 \times 10^{+5}$	12	8	$7,0737 \times 10^{+9}$	n.a.
<b><math>K = 16</math> usuários</b>					
WS-ALM	40,84	4	4	1338832	n.a.
WS-SQP	10,38587	12	8	223369	n.a.
$\epsilon$ -C-ALM	<b>5,17</b>	12	<b>12</b>	205748	<b><math>2,0858 \times 10^{-8}</math></b>
$\epsilon$ -C-SQP	8,77	12	<b>12</b>	<b>192805</b>	$5,0743 \times 10^{-8}$
<b><math>K = 32</math> usuários</b>					
WS-ALM	<b>4,26</b>	12	6	1135008	n.a.
WS-SQP	19,72759	12	8	<b>435603</b>	n.a.
$\epsilon$ -C-WS-ALM	19,46	12	<b>12</b>	735299	<b><math>8,4067 \times 10^{-9}</math></b>
$\epsilon$ -C-SQP	22,73	12	<b>12</b>	476584	$1,1324 \times 10^{-8}$

A Figura 33 mostra a dependência clássica entre EE e SE considerando os parâmetros de sistema adotados nesta seção. Pode-se notar que a curva obtida é em forma de sino e também é côncava no domínio considerado. O gráfico também mostra

a natureza conflitante da otimização simultânea de SE e EE, isto é, o SE máximo é atingível depois que o EE atinge seu nível máximo e diminui monotonicamente. De fato, os pontos que satisfazem a solução de RE de múltiplos objetivos podem ser identificados nos segmentos das curvas compreendidos entre os pontos onde ocorre  $\max \eta_{EE}$  e  $\max_{SE}$ , representando as soluções da fronteira de Pareto na Figura 31.



**Figura 33:** Relação EE-SE destacando o ponto de EE máximo e SE máximo para o recurso de potência disponível.

**Fonte:** Autoria própria

A Figura 34 apresenta a fronteira de Pareto obtida para os dois métodos de MOO considerados a solução de RE de múltiplos objetivos, isto é, a solução do compromisso EE-SE OCDMA. Observe que, para  $K = 8$  e 32 usuários, a fronteira de Pareto obtida é proporcional. No entanto, para  $K = 16$ , o método WS não converge para  $0, 27 < \lambda \leq 1$ . Para esse intervalo de valores, o ALM para no mesmo ponto, próximo ao último limite de Pareto obtido pelo método  $\epsilon$ -C sem atingir a factibilidade. Note-se também que o método WS repetiu soluções e, como esperado devido à sua construção, as soluções não são distribuídas uniformemente sobre a curva.

A Figura 35 mostra a evolução da soma de potências em relação a  $\lambda$  (12 valores de  $\lambda$ , conforme Tabela 19) para o método WS e  $\epsilon$  (12 valores de  $\epsilon$ , conforme Tabela 19) para o método  $\epsilon$ -C. Pode-se observar que, para  $K = 16$  usuários, o método WS-ALM não converge quando  $\lambda > 0, 27$ . Por outro lado, para  $K = 8$  e  $K = 32$ , pode-se verificar que ambos os métodos atingem os mesmos níveis de potência finais para a solução do



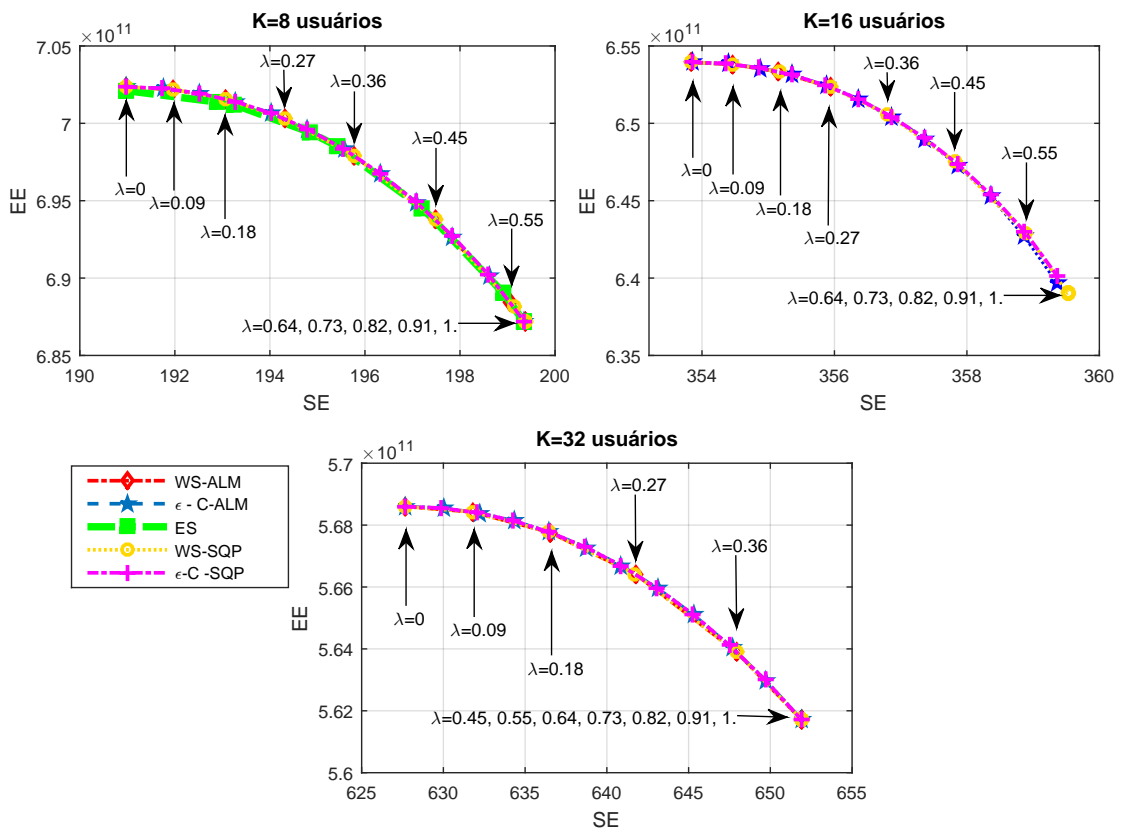
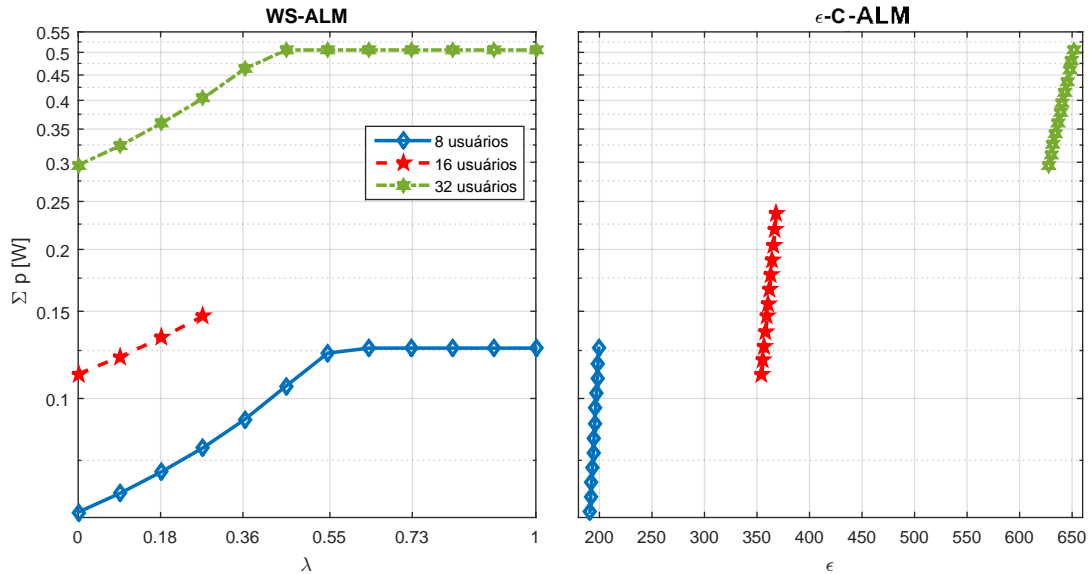


Figura 34: Fronteira de Pareto obtidas pelos métodos WS-ALM, WS-SQP,  $\epsilon$ -C-ALM e  $\epsilon$ -C-SQP por  $K \in \{8; 16; 32\}$  usuários. Além disso, para  $K = 8$  usuários, as Fronteira de Pareto são obtidas pelo método de Busca Exaustiva.

Fonte: Autoria própria

problema EE-SE OCDMA.




**Figura 35: Evolução da soma de potências para ambos os métodos de MOO considerando  $K \in \{8, 16, 32\}$  usuários.**

**Fonte: Autoria própria**

A Figura 36(a) plota o fator de ponderação  $\lambda$  versus EE e SE para melhor visualização do compromisso EE-SE, considerando o método WS-ALM e  $K = 32$  usuários. Como pode ser visto, a EE correspondente diminui com o aumento de  $\lambda$ , enquanto o SE correspondente aumenta com o aumento de  $\lambda$ . Isso ocorre porque o aumento de  $\lambda$  fornece mais peso à SE portanto, mais recursos são alocados para maximizar a SE. Além disso, os EE e SE correspondentes permanecem os mesmos (efeito “ saturado ”) quando o fator de ponderação  $\lambda$  se torna grande. Portanto, quando  $\lambda$  for pequeno, ambos os métodos de MOO para RE focam na otimização de EE, porém otimizará o SE quando  $\lambda$  for grande. Uma análise semelhante do compromisso entre EE-SE para  $K = 32$ , mas agora considerando o método  $\epsilon$ -C, pode ser realizada observando a Figura 36 (b). Como já observado na Figura 36(a), o EE correspondente diminui com o aumento da restrição  $\epsilon$  enquanto o SE correspondente aumenta. Isso ocorre porque o aumento da restrição  $\epsilon$  aumenta o requisito de SE e, portanto, mais recursos são alocados para satisfazer a restrição. Os últimos pares de pontos obtidos nas figuras representam o  $\max \eta_{SE}$  e o respectivo valor de EE neste ponto. Note que para  $\lambda > 0,4$  WS repete essa solução.


A maximização de EE para diferentes níveis máximos de potência ( $p_{\max}$ ) é considerada na Figura 37 para usuários de  $K = 8, 16$  e 32. Pode-se observar que, nos três casos, o valor máximo de EE para potências máximas iguais ou superiores a 10dBm permanece



**Figura 36:** Impacto do fator de peso  $\lambda$  e a restrição  $\epsilon$  no compromisso EE-SE considerando os métodos WS e  $\epsilon$ -C, respectivamente.

**Fonte:** Autoria própria

quase constante, o que indica que a EE máxima para a rede considerada, é alcançada adotando-se uma disponibilidade de potência de transmissão no laser, próximo ou superior a 10dBm. Assim, aumentando gradativamente o  $p_{\max}$  disponível para além de 10mW não altera o ponto de equilíbrio de  $\max \eta_{EE}$ .



**Figura 37:** Variação de EE para diferentes níveis máximos de potência.

**Fonte:** Autoria própria

Para obter mais informações, simulações numéricas adicionais comparando o SE máximo atingível e os seus respectivos valores de EE são resumidas na Figura 38, admitindo um número diferente de nós ópticos e uma potência disponível máxima variando em  $p_{\max} \in [2; 20]$ dBm. Os gráficos indicam que o valor máximo de EE ocorre em diferentes níveis de potência de transmissão, obviamente devido à combinação entre o número diferente de usuários e o consumo de energia do circuito associado. Pode-se observar a tendência de evolução côncava da EE, quando comparada ao comportamento monotônico crescente da SE. De fato, primeiro, a EE aumenta, atinge o pico e depois começa a se degradar. Dois conjuntos de pontos merecem destaque pelo comportamento da curva EE. Para usuários  $K = 8$ , a EE máxima é atingida quando a potência máxima de transmissão é  $p_{\max} = 8$ dBm. Este ponto fornece o EE máximo, porém com SE reduzida. Esses pontos podem ser considerados ideais na otimização de EE para cada cenário específico de configuração de canal e sistema.

O segundo conjunto de pontos que merece destaque é a região que define o compromisso de EE-SE associado à fronteira de Pareto. Na Figura 38(a) para  $K = 8$  entre  $p = 8$  e 20dBm, podemos observar que EE é decrescente em relação ao  $\max \eta_{EE}$  enquanto  $\eta_{SE}$  aumenta monotonicamente. Portanto, podemos esperar uma melhor troca entre EE e SE na região à direita da linha tracejada vertical em  $p_{\max EE} = 8$  dBm, devido a um aumento significativo de  $\eta_{SE}$ . O mesmo comportamento pode ser observado para um número maior de usuários. De fato, para  $K = 16$ , a Figura 38(b) indica que a compensação EE-SE é definida pelo limite de  $p_{\max EE} = 8$ dBm, enquanto para usuários de  $K = 32$ , na Figura 38(c), a potência de transmissão para o EE máximo é definida em  $p_{\max EE} = 10$ dBm. Esses conjuntos de potências de transmissão do laser podem ser considerados os pontos ideais em termos de o sistema atingir um equilíbrio favorável entre EE e SE. Essas regiões de operação otimizam conjuntamente a  $\eta_{EE}$  e a  $\eta_{SE}$  da rede OCDMA para cada canal específico e configuração do sistema.

A Figura 39 apresenta uma comparação entre os métodos analisados em relação aos números de funções avaliadas para solucionar o problema no Cenário B, em geral, foi observado o mesmo comportamento do Cenário A, com exceção do método WS-ALM para  $K = 16$  usuários, que consumiu significativamente menos avaliações, devido ao fato do método divergir para  $\lambda > 0,27$  sendo, portanto destacado da análise nesta condição.

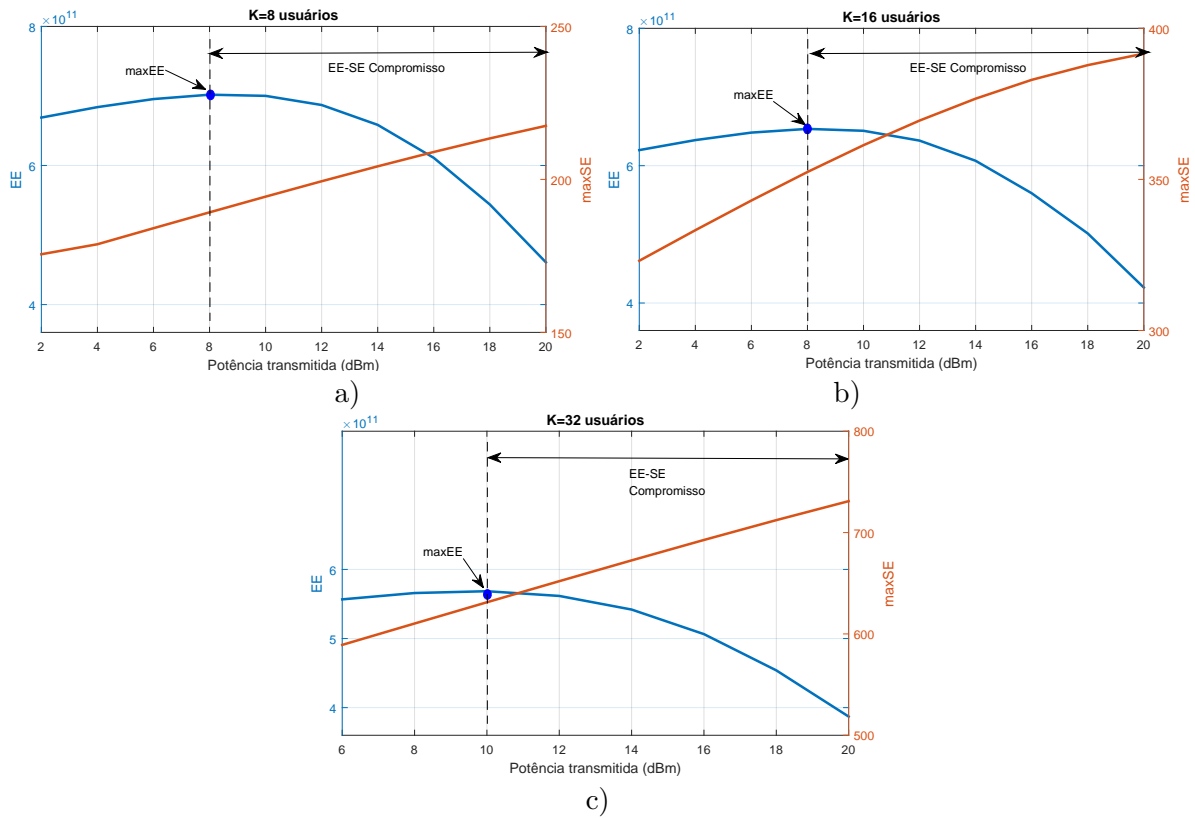


Figura 38: Desempenho de EE e max-SE em relação à potência disponível máxima  $p_{max}$  para  $K = 8, 16$  e  $32$  usuários.

Fonte: Autoria própria




Figura 39: Evolução do número total de avaliação de funções dos métodos testados para  $K = [8, 16, 32]$  usuários.

Fonte: Autoria própria

## 6.4 CONCLUSÕES DO CAPÍTULO

Os resultados numéricos demonstraram que o compromisso EE-SE pode ser tratado adequadamente por meio do método  $\epsilon$ -C e da estratégia WS dentro de uma abordagem multiobjetivo dado a natureza conflitante entre EE e SE do ponto de vista de alocação de recursos no sistema óptico OCDMA. Além disso, os métodos WS e  $\epsilon$ -C são capazes de encontrar soluções EE-SE na fronteira de Pareto, ou seja, as soluções obtidas pelos dois métodos MOO são soluções de Pareto para o problema de otimização do RE-OCDMA devido ao fato de às características das soluções encontradas estarem em concordância com os Teoremas 2 e 3. Também pode-se observar através dos testes numéricos realizados que o método  $\epsilon$ -C encontrou maior diversidade de soluções na fronteira de Pareto em relação ao método WS, indicando que o primeiro método é mais adequado e eficiente na otimização do compromisso EE-SE em redes OCDMA.

Os bons resultados do método  $\epsilon$ -C nos testes realizados se devem às características das funções componentes do compromisso EE-SE, as quais possibilitaram validar os resultados apresentados Teorema 3. Assim, se a restrição (C. $\epsilon$ ) for satisfeita como uma igualdade, então as soluções encontradas estão na fronteira de Pareto, ou seja, são soluções eficientes.

## 7 CONCLUSÕES E TRABALHOS FUTUROS

Esta Tese propôs e analisou técnicas de otimização na resolução de problemas de alocação de recursos em redes ópticas OCDMA. O desenvolvimento destes algoritmos foi realizado avaliando-se os resultados numéricos em redes nas quais o modelo de sistema opera no limite da robustez, possibilitando uma investigação profunda em relação à complexidade computacional. Foram abordados diferentes problemas de otimização associados ao consumo eficiente de potência no laser transmissor em redes ópticas CDMA, incluindo a maximização da eficiência energética, minimização do controle de potência, bem como o compromisso EE-SE em redes OCDMA. Dentre as técnicas de otimização adotadas destacamos as técnicas de programação não-linear, meta-heurísticas, redes neurais artificiais além das técnicas de otimização multiobjetivo como alternativas para solução de problemas relacionados à alocação dos recursos.

No Capítulo 1 foi apresentada a introdução e justificativa para a pesquisa realizada, bem como os objetivos e contribuições desta Tese. No Capítulo 2 apresentamos brevemente o modelo do sistema OCDMA-PON e sua estrutura física, bem como os problemas de alocação de recursos em redes OCDMA considerados nesta Tese.

No Capítulo 3 uma rede neural artificial baseada na topologia de Hopfield foi utilizada como estratégia de resolução para o problema de controle de potência. Os resultados de simulação mostraram que a rede neural modificada proposta fornece resultados expressivos, tornando-se assim um método alternativo para resolver o problema eficientemente. Os parâmetros internos da rede foram obtidos utilizando conceitos relativos às teorias de otimização não-linear e de estabilidade de Lyapunov. O mapeamento de problemas de otimização não-linear restrita através da rede mH-NN, além de fornecer um novo método para resolver esses problemas, não requer a definição (ajuste) de nenhum parâmetro de penalidade ou ponderação. Os resultados obtidos nos testes numéricos mostram que a rede mH-NN para o problema de alocação de potência mínima convergiu nos casos considerados, e que já após a primeira iteração externa o método fornece aproximações muito boas. É importante notar também que a rede mH-NN geralmente

consome muitas iterações para alcançar a convergência em problemas de programação não linear, apesar da direção utilizada para otimizar a função objetivo na Etapa III do Algoritmo 1 ser oposta ao gradiente de  $J_1$ . No entanto, e pelo fato da função  $J_1$  ser uma função linear em relação a  $\mathbf{p}$ , esta direção oposta ao gradiente contribuiu para os bons resultados alcançados para esta classe de problemas.

Em relação ao problema de maximização da eficiência energética em sistemas ópticos CDMA, no Capítulo 4, foi realizada primeiramente a análise de quatro métodos de programação não linear. Os resultados obtidos nos levam a concluir que o método DK pode não ser indicado para o problema EE-OCDMA devido ao seu alto custo computacional, enquanto o ALM, SQP e o método MaMi apresentaram uma relação de desempenho e complexidade adequadas no mesmo contexto e cenários de rede. Assim, os métodos de otimização SQP, ALM e MaMi demonstraram ser opções promissoras na resolução do problema de otimização da eficiência energética em sistemas OCDMA, tanto do ponto de vista da qualidade das soluções quanto da complexidade/implementabilidade.

No Capítulo 5, em redes maiores, o problema EE tende a se tornar mais difícil devido à dimensionalidade do problema de otimização associado. Os métodos PSO e PSOGSA combinados ao ALM, mostraram-se promissores considerando o reduzido tempo de convergência para solução do problema EE. O uso do ALM em conjunto com métodos heurísticos mostrou-se uma excelente alternativa que busca unir as boas propriedades do ALM com a diversidade e maleabilidade dos métodos heurísticos. Podemos destacar que o uso da técnica ALM foi além de uma função *fitness* para o problema. O uso do ALM não aumenta significativamente o custo computacional e, além disso permite utilizar os critérios de parada usuais do ALM. Outro destaque é que o método ALM fornece um *feedback* da solução, ou seja, pôde-se medir com maior precisão a qualidade da solução através da factibilidade e optimalidade. O desempenho do método ALM-BFGS poderia ser melhorado se várias inicializações fossem consideradas (*multi-starts*), porém esta estratégia o tornaria significativamente mais lento e, conseqüentemente, menos competitivo.

Por fim, esta Tese também analisou, no Capítulo 6, o compromisso EE-SE em redes OCDMA. O problema de eficiência de recursos RE em redes OCDMA pode ser tratado adequadamente por meio das técnicas de MOO,  $\epsilon$ -C e WS. Confirmou-se que os métodos WS e  $\epsilon$ -C se mostraram capazes de encontrar soluções para o compromisso EE-SE na fronteira de Pareto. Destaque-se também que os testes numéricos mostraram que o método  $\epsilon$ -C pode determinar maior diversidade de soluções na fronteira de Pareto



em relação ao método WS, demonstrando que o método  $\epsilon$ -C é indicado para resolver eficientemente o problema do compromisso EE-SE em redes OCDMA.

Os resultados obtidos nesta Tese se mostram promissores, com contribuição científica significativa na área de pesquisa em redes OCDMA, por fazerem uso de técnicas de programação não-linear relacionadas à alocação de recursos com baixa complexidade computacional. Estas técnicas de otimização propostas favorecem a operação de sistemas OCDMA capaz de operar com menor quantidade de potência consumida, otimizando a eficiência global da rede de comunicação óptica.

No desenvolvimento desta Tese foram identificados temas e problemas cuja resolução apresentada na literatura pode ser melhorada. Desta forma são perspectivas para trabalhos futuros:

- Explorar a maximização da eficiência energética através da rede neural artificial de Hopfield modificada;
- Explorar o problema de alocação do compromisso EE-SE através do método de otimização MaMi;
- Explorar alocação de recursos em redes ópticas CDMA com a meta-heurística de Hill Climbing comparado aos métodos de otimização abordados neste trabalho;
- Analisar variações e novas alternativas para os métodos de PNLs aplicados nesta Tese relacionadas aos problemas de alocação de recursos em redes de telecomunicações.

## REFERÊNCIAS

- ABD, T. H. et al. Enhancement of performance of a hybrid sac-ocdma system using dynamic cyclic shift code. **Ukr. J. Phys. Opt.**, v. 13, p. 488–494, 2012.
- ABDULLAH, A. R. A. J. et al. Mitigation of multiple access interference using two-dimensional modified double weight codes for optical code division multiple access systems. **Optical Engineering**, v. 51, n. 6, p. 1 – 11, 2012.
- AHMED, G.; DJEBBARI, A.; ABDELMALIK, T. Exact analysis of signal-to-noise ratio for sac-ocdma system with direct detection. **Optik-International Journal for Light and Electron Optics**, v. 145, 2017.
- AHMED, H. Y. et al. A configurable transmitter-receiver structure to support qos for spectral amplitude coding-optical code division multiple access. **Optical Fiber Technology**, v. 58, p. 102232, 2020.
- AIYER, S. V. B.; NIRANJA, M.; FALLSIDE, F. A theoretical investigation into the performance of the hopfield model. **IEEE Transactions on Neural Networks**, v. 1, p. 53–60, 1990.
- ALIANO, F. A. **Novas extensões de técnicas de escalarizações no problema de corte unidimensional inteiro multiobjetivo**. 204 p. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, SP, Brasil, 2016.
- ALVES, T. A. B. et al. Power allocation scheme for ocdma ng-pon with proportional-integral-derivative algorithms. **J. Opt. Commun. Netw.**, v. 8, n. 9, p. 645–655, 2016.
- AMIN, O. et al. Energy efficiency-spectral efficiency tradeoff: A multiobjective optimization approach. **IEEE Transactions on Vehicular Technology**, v. 65, n. 4, 2016.
- ANDREANI, R. et al. On augmented lagrangian methods with general lower-level constraints. **SIAM Journal on Optimization**, v. 18, p. 1286–1309, 2007.
- ANDREANI, R. et al. On augmented lagrangian methods with general lower-level constraints. **SIAM Journal on Optimization**, p. 1286–1309, 2007.
- ASAKA, K. Consideration of tunable components for next-generation passive optical network stage 2. **Journal of Lightwave Technology**, v. 33, n. 5, p. 1072–1076, 2015.
- BALDI, M. et al. Code-based physical layer secret key generation in passive optical networks. **Ad Hoc Networks**, v. 89, p. 1–8, 2019.
- BEYRANVAND, H.; GHAFARI, B.; SALEHI, J. A. Multirate, differentiated-qos, and multilevel fiber-optic cdma system via optical logic gate elements. **J. Lightwave Technol.**, v. 27, n. 19, p. 4348–4359, 2009.

- BEYRANVAND, H. et al. Performance analysis of equal-energy two-level ocdma system using generalized optical orthogonal codes. **Journal of Lightwave Technology**, v. 31, n. 10, p. 1573–1584, 2013.
- BIRGIN, E. G. et al. Outer trust-region method for constrained optimization. **J Optim Theory Appl**, p. 142–150, 2011.
- BOYD, S.; VANDENBERGHE, L. Convex optimization. **Cambridge, U.K.: Cambridge Univ. Press**, 2004.
- CASTELANI, E. V. et al. Addressing the greediness phenomenon in nonlinear programming by means of proximal augmented lagrangians. **Computational Optimization and Applications**, p. 229–245, 2010.
- CHEN, C. et al. Performance analysis of double-weight optical cdma under the same-bit-power assumption. **IEEE Transactions on Communications**, v. 59, n. 5, p. 1247–1252, 2011.
- CHEN, Y. et al. Fundamental trade-offs on green wireless networks. **IEEE Communications Magazine**, v. 49, n. 6, p. 30–37, 2011.
- DINKELBACH, W. On nonlinear fractional programming. **Manage. Sci.**, v. 13, n. 7, p. 492–498, 1967.
- DURAND, F. R.; ABRAO, T. Energy efficient adaptive optical cdma random access protocol based on particle swarm optimization. **Photonic Netw. Commun.**, v. 33, n. 3, p. 275–289, 2017.
- DURAND, F. R.; FILHO, M. S.; ABRAO, T. The effects of power control on the optical cdma random access protocol. **Optical Switching and Networking**, v. 34, n. 3, p. 117–167, 2015.
- EHRGOTT, M.; RUZIKA, S. Improved  $\epsilon$ -constraint method for multiobjective programming. **Journal of Optimization Theory and Applications**, Springer New York, v. 138, n. 3, p. 375–396, 2008.
- FOSCHINI, G. J.; SALZ, J. Digital communications over fading radio channels. **Bell System Technical Journal**, v. 62, n. 2, p. 429–456, 1983.
- GANTMACHER, F. The theory of matrices. **Chelsea Publishing Company**, 1964.
- GOLDSMITH, A. Wireless communications. **Stanford University Press**, 2002.
- GOODMAN, D. J.; MANDAYAN, N. B. Power control for wireless data. **IEEE. Personal Communication Magazine**, v. 7, n. 4, p. 48–54, 2000.
- 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 , Communications**, v. 65, n. 4, p. 361–372, 2011.
- HADI, M.; PAKRAVAN, M. R. Analysis and design of adaptive ocdma passive optical networks. **J. Lightwave Technol.**, v. 35, n. 14, p. 2853–2863, 2017.

- HADI, M.; PAKRAVAN, M. R. Analysis and design of adaptive ocdma passive optical networks. **Journal of Lightwave Technology**, v. 35, n. 14, p. 2853–2863, 2017.
- HADI, M.; PAKRAVAN, M. R. Rate-maximized scheduling in adaptive ocdma systems using stochastic optimization. **IEEE Communications Letters**, v. 22, n. 4, p. 728–731, 2018.
- HAIMES, Y. Y.; LASDON, L. S.; WISMER, D. A. On a bicriterion formulation of the problems of integrated system identification and system optimization. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-1, n. 3, p. 296–297, 1971.
- HEDDEGHEM, W. V. et al. Power consumption modeling in optical multilayer networks. **Photon. Netw. Commun.**, v. 24, n. 2, p. 86–102, 2012.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **IEEE Circuits and Devices Magazine**, p. 1–10, 1982.
- IMTIAZ, W. A. et al. An optimized architecture to reduce the impact of fiber strands in spectral/spatial optical code division multiple access passive optical networks (ocdma-p). **Optical Fiber Technology**, v. 54, p. 102072, 2020.
- INATY, E. et al. Code division multiple access enabled dynamic bandwidth allocation (cdba) scheme for epon. **J. Opt. Commun. Netw.**, v. 4, n. 3, p. 271–281, 2012.
- JABER, A. A. k.; MOHAMMED, S. J.; MURDAS, I. A. Simulation of a sac-ocdma 15 user system using hadamard code. **2019 1st AL-Noor International Conference for Science and Technology (NICST)**, p. 38–41, 2019.
- KAZOVSKY, L.; GOWDA, A. S.; PRAT, J. Small networks, large energy: New frontiers in green it. **19th International Conference on Transparent Optical Networks (ICTON)**, p. 1–6, 2017.
- KENNEDY, M. P.; CHUA, L. O. Neural networks for nonlinear programming. *IEEE transactions on circuits and systems*. **IEEE Transactions on Circuits and Systems**, v. 35, p. 554–562, 1988.
- KERAF, N. D. et al. Performance of 2-d hybrid fcc-mdw code on ocdma system with the presence of phase induced intensity noise. **ARPN J. Eng. Appl. Sci.**, p. 13203–1320, 2016.
- KHOUKHI, A. et al. Non-linear constrained optimal control problem: A hybrid pso-ga-based discrete augmented lagrangian approach. **2011 Annual Meeting of the North American Fuzzy Information Processing Society**, p. 1–6, 2011.
- KITAYAMA, K. Code Division Multiplexing Lightwave Networks Based upon Optical Code Conversion. **IEEE Journal on Selected Areas in Communications**, v. 16, n. 7, p. 1309–1319, 1998.
- KUMAWAT, S.; MADDILA, R. K. Development of zccc for multimedia service using sac-ocdma systems. **Optical Fiber Technology**, v. 39, p. 12–20, 12 2017.

- KWONG, W. C.; YANG, G. Design of multilength optical orthogonal codes for optical cdma multimedia networks. **IEEE Transactions on Communications**, v. 50, n. 8, p. 1258–1265, 2002.
- LI, C.-Y. et al. Optical add/drop multiplexer for tree-based passive optical networks. **Optical Fiber Technology**, v. 54, 2020.
- LIN, B. et al. Experimental demonstration of scma-ofdm for passive optical network. **Optical Fiber Technology**, v. 39, p. 1–4, 2017.
- LUENBERGER, D. G.; YE, Y. Linear and nonlinear programming. **Addison Wesley, Springer**, 2008.
- MAODE, M.; YONGQING, Z. A bandwidth guaranteed polling mac protocol for ethernet passive optical networks. **IEEE Communications Magazine**, p. 98–107, 2002.
- MARQUES, M. P. et al. WDM/OCDM Energy-Efficient Networks Based on Heuristic Ant Colony Optimization. **IEEE Systems Journal**, v. 10, p. 1482–1493, 2016.
- MARTINEZ, C. A. P. et al. Augmented lagrangian combined to evolutionary heuristic for energy efficiency in ocdma networks. **Optical Switching and Networking**, v. 36, p. 100542, 2020.
- MATEM, R. et al. Photodetector effects on the performance of 2d spectral/spatial code in ocdma system. **Optik -International Journal for Light and Electron Optics**, v. 178, p. 1051–1061, 2019.
- MESHKATI, F.; POOR, H. V.; SCHWARTZ, S. C. Energy-efficient resource allocation in wireless networks. **IEEE Signal Processing Magazine**, v. 24, n. 3, p. 58–68, 2007.
- M'FOUBAT, A. O.; ELBAHHAR, F.; TATKEU, C. Multiuser interference cancellation in a passive network with pon-ocdma uncontrolled power. **2011 3rd International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)**, p. 1–5, 2011.
- MIAO, G.; HIMAYATA, N.; LY, T. Energy-efficient link adaptation in frequency-selective channels. **IEEE Transactions on**, v. 58, n. 2, p. 545–554, 2010.
- MIRJALILI, S.; HASHIM, S. Z. M. A new hybrid psogsa algorithm for function optimization. **2010 International Conference on Computer and Information Application**, p. 374–377, 2010.
- MUKHERJEE, B. WDM Optical Communication Networks: Progress and Challenges. **Journal of Selected Areas in Communications**, v. 18, n. 10, p. 1810–1824, 2000.
- NAGHSH, M. M. et al. Efficient Sum-Rate Maximization for Medium-Scale MIMO AF-Relay Networks. **IEEE Trans. Wireless Commun.**, v. 21, n. 1, p. 112–114, 2004.
- NOCEDAL, J.; WRIGHT, S. Numerical optimization. springer series in operations research. **Springer**, 2006.
- PENDEZA MARTINEZ, C. A.; DURAND, F. R.; ABRAO, T. Energy-efficient qos-based ocdma networks aided by nonlinear programming methods. **AEU- International Journal of Electronics and Communications**, v. 98, p. 144 – 155, 2019.

- PINHEIRO, J. M. S. Redes ópticas de acesso em telecomunicações. **Elsevier Editora Ltda**, Rio de Janeiro, 2017.
- RAO, S. S. Engineering optimization: theory and practice. **John Wiley and Sons**, Canadá, 2009.
- RASHEDI, E.; HOSSEIN, N.; SAEID, S. Gsa: A gravitational search algorithm. **Inf. Sci.**, v. 179, n. 13, p. 2232–2248, 2009.
- REVIRIEGO, P. et al. Energy efficiency in ethernet. **John Wiley & Sons, Ltd**, p. 277–290, 2015.
- RICHARDSON, D.; FINI, J.; NELSON, L. Space–division multiplexing in optical fibres. **Nature Photon**, v. 7, p. 354–362, 2013.
- RICKEN, L. et al. The impact of geographic distribution in passive optical network with optical cdma. **Latin America Transactions, IEEE**, v. 13, p. 2152–2158, 2015.
- SAFARI, A.; SHAYANFAR, H. A.; KAZEMI, A. Robust pwm-sc damping controller tuning on the augmented lagrangian pso algorithm. **IEEE Transactions on Power Systems**, v. 28, n. 4, p. 4665–4673, 2013.
- SANTOS, A. J. **Estudo de Alocação de Recursos em Redes ópticas WDM/OCDM baseada em Inteligência de Enxame de Partículas**. 86 p. Dissertação (Mestrado) — Universidade Estadual de Londrina, Londrina, PR, Brasil, 2015.
- SANTOS, L. R. R. et al. Auto-tuning pid distributed power control for next-generation passive optical networks. **Journal of Optical Communications and Networking**, v. 10, p. D110–D125, 2018.
- SCHAIBLE, S. Fractional programming. ii, on dinkelbach’s algorithm. **Manage. Sci.**, v. 22, n. 8, p. 868–873, 1976.
- SCHAIBLE, S.; IBARAKI, T. Fractional programming. **European Journal of Operational Research**, v. 12, n. 4, p. 325–338, 1983.
- SEDLACZEK, K.; EBERHARD, P. Using augmented lagrangian particle swarm optimization for constrained problems in engineering. **Structural and Multidisciplinary Optimization**, v. 32, n. 4, p. 277–28, 2006.
- SHANNON, C. E. The mathematical theory of communication. **The Bell System Technical Journal**, v. 27, p. 379–423, 1948.
- SHOREH, M. H.; BEYRANVAND, H.; SALEHI, J. A. Performance evaluation of asynchronous multi-carrier code division multiple access for next generation long-reach fibre optic access networks. **IET Optoelectron**, v. 9, n. 6, p. 325–332, 2015.
- SILVA, I. N. Stability and convergence analysis of a neural model applied in nonlinear systems optimization. **Lecture Notes in Computer Science**, v. 2714, p. 189–197, 2003.
- SINGH, S.; SINGH, S. Performance analysis of spectrally encoded hybrid wdm-ocdma network employing optical orthogonal modulation format against eavesdropper. **AEU - International Journal of Electronics and Communications**, v. 82, p. 492 – 501, 2017.

- SINGH, S.; SINGH, S. Performance analysis of spectrally encoded hybrid wdm-ocdma network employing optical orthogonal modulation format against eavesdropper. **AEU - International Journal of Electronics and Communications**, v. 82, p. 492 – 501, 2017.
- SLOTINE, J. E.; LI, W. Applied nonlinear control. **Englewood Cliffs, N.J Prentice Hall**, 1991.
- SONG, Z.; NI, Q.; SUN, X. Spectrum and energy efficient resource allocation with qos requirements for hybrid mc-noma 5g systems. **IEEE Access**, v. 6, p. 37055–37069, 2018.
- STOICA, P.; SELEN, Y. Cyclic minimizers, majorization techniques, and the expectation-maximization algorithm: a refresher. **IEEE Signal Process. Mag.**, v. 21, n. 1, p. 112–114, 2004.
- SUN, Y.; BABU, P.; PALOMAR, D. P. Majorization-minimization algorithms in signal processing, communications, and machine learning. **IEEE Trans on Signal Processing**, v. 65, n. 3, p. 794–816, 2017.
- TALBI, E. G. A taxonomy of hybrid metaheuristics. **Journal of Heuristics**, v. 8, n. 5, p. 541–564, 2002.
- TANG, J. et al. Energy efficiency optimization for noma with swipt. **IEEE Journal of Selected Topics in Signal Processing**, v. 13, n. 3, p. 452–466, 2019.
- TARHUNI, N. et al. Power control of optical cdma star networks. **Optics Communications**, v. 259, p. 655–664, 2006.
- TARHUNI, N. G. Investigation of multi-beam interference impact on state-of-polarization ocdma optical networks. **International Symposium on Networks, Computers and Communications (ISNCC)**, p. 1–6, 2019.
- TEH, P. C. et al. Demonstration of a four-channel wdm/ocdma system using 255-chip 320-gchip/s quarternary phase coding gratings. **IEEE Photonics Technology Letters**, v. 14, n. 2, p. 227–229, 2002.
- TSENG, C.; WANG, L.; KUO, C. Application of hybrid mixing cdma/idma/ocdma/oidma for smart grid integration of renewable-energy resources. **International Symposium on Computer, Consumer and Control (IS3C)**, p. 878–882, 2016.
- TUCKER, R. S. Green optical communications - part ii: Energy limitations in networks. **IEEE J Selected Topics in Quantum Electronics**, v. 17, n. 2, p. 261–274, 2011.
- UDALCOVS, A. et al. Analysis of spectral and energy efficiency tradeoff in single-line rate wdm links. **J. Lightwave Technol.**, OSA, v. 35, n. 10, p. 1847–1857, 2017.
- VAZQUEZ, A. R. et al. Nonlinear switched-capacitor neural network for optimization problems. **IEEE Transactions on Circuits and Systems**, v. 37, p. 554–562, 1990.
- VIDYASAGAR, M. Nonlinear systems analysis. **Prentice-Hall, Englewood Cliffs, New Jersey**, 1992.

VILELA, A. C. P. C. **Estudo sobre Tecnologias Candidatas à Próxima Geração de Redes ópticas passivas e cenário de coexistência na rede de acesso**. Dissertação (Mestrado) — Universidade Federal Fluminense, Niterói, RJ, Brasil, 2017.

WONG, E. Next-generation broadband access networks and technologies. **Journal of Lightwave Technology**, v. 30, n. 4, p. 597–608, 2012.

WU, B. B.; PRUCNAL, P. R.; NARIMANOV, E. E. Secure transmission over an existing public wdm lightwave network. **IEEE Photonics Technology Letters**, v. 18, p. 1870–1872, 2006.

YANG, G.; KWONG, W. Performance analysis of optical cdma with prime codes. **Electronics Letters**, v. 31, n. 7, p. 569–570, 1995.

YASHIMA, H.; KOBAYASHI, T. Optical cdma with time hopping and power control for multimedia networks. **Journal of Lightwave Technology**, v. 21, n. 3, p. 695–702, 2003.

YIN, H.; RICHARDSON, D. J. Optical code division multiple access communication networks: theory and applications. **Berlin: Springer-Verlag and Tsinghua University Press**, 2009.

YIRAN, M. et al. Demonstration of a 40gb/s time and wavelength division multiplexed passive optical network prototype system. **Optical Fiber Communication Conference**, p. PDP5D.7, 2012.

ZULAI, L.; DURAND, F. R.; ABRAO, T. Energy-efficient next-generation passive optical networks based on sleep mode and heuristic optimization. **Fiber and Integrated Optics**, v. 34, n. 3, p. 117–137, 2015.

ZUO, Y. et al. Energy efficiency and spectral efficiency tradeoff for multicarrier noma systems with user fairness. **2018 IEEE/CIC International Conference on Communications in China (ICCC)**, p. 666–670, 2018.