

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**DEPARTAMENTO DE ELETRÔNICA E SISTEMAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**MATHEUS RIBEIRO SENA**

**UM ESTUDO SOBRE OTIMIZAÇÕES EVOLUCIONÁRIAS NA MITIGAÇÃO DE  
EFEITOS NÃO-LINEARES EM CANAIS ÓPTICOS ELÁSTICOS**

Recife

2018

MATHEUS RIBEIRO SENA

**UM ESTUDO SOBRE OTIMIZAÇÕES EVOLUCIONÁRIAS NA MITIGAÇÃO DE  
EFEITOS NÃO-LINEARES EM CANAIS ÓPTICOS ELÁSTICOS**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como requisito parcial para a obtenção do grau de mestre em Engenharia Elétrica.

Área de concentração: Comunicações.

Orientador: Prof<sup>o</sup>. Dr. Raul Camelo de Andrade Almeida Júnior

Recife

2018

Catálogo na fonte  
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

S474u Sena, Matheus Ribeiro.  
Um estudo sobre otimizações evolucionárias na mitigação de efeitos não-lineares em canais ópticos elásticos / - 2018.  
73 folhas, il., tab. e símb.

Orientador: Prof. Dr. Raul Camelo de Andrade Almeida Júnior.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2018.  
Inclui Referências e Apêndices.

1. Engenharia Elétrica. 2. Redes ópticas elásticas. 3. Não-linearidade. 4. Otimização por enxame de partículas. 5. Algoritmos genéticos. I. Almeida Júnior, Raul Camelo de Andrade (Orientador). II. Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2019-064



# Universidade Federal de Pernambuco

## *Pós-Graduação em Engenharia Elétrica*

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE  
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

# MATHEUS RIBEIRO SENA

TÍTULO

**“UM ESTUDO SOBRE OTIMIZAÇÕES EVOLUCIONÁRIAS NA  
MITIGAÇÃO DE EFEITOS NÃO-LINEARES  
EM CANAIS ÓPTICOS ELÁSTICOS”**

A comissão examinadora composta pelos professores: RAUL CAMELO DE ANDRADE ALMEIDA JÚNIOR, DES/UFPE; JOAQUIM FERREIRA MARTINS FILHO, DES/UFPE, e DANIEL AUGUSTO RIBEIRO CHAVES, DEC/UPE, sob a presidência do primeiro, consideram o candidato **MATHEUS RIBEIRO SENA** **APROVADO**.

Recife, 20 de dezembro de 2018.

---

**MARCELO CABRAL CAVALCANTI**  
Coordenador do PPGEE

---

**RAUL CAMELO DE ANDRADE ALMEIDA  
JÚNIOR**  
Orientador e Membro Titular Interno

---

**DANIEL AUGUSTO RIBEIRO CHAVES**  
Membro Titular Externo

---

**JOAQUIM FERREIRA MARTINS FILHO**  
Membro Titular Interno

*À minha família, por sua capacidade de acreditar em mim e investir nos meus estudos.*

## **AGRADECIMENTOS**

Agradeço a Deus, que por Cristo me concedeu Sua maravilhosa graça e que motiva todos os meus trabalhos durante esta vida.

Agradeço em especial aos meus pais, Gabriel e Vera, e minhas irmãs, Rafaela e Gabrielle, por quem minha admiração só cresce a cada dia. Agradeço às minhas tias, Gabriela e Erotides, por todo cuidado até hoje concebido a mim.

Agradeço à minha namorada Camila pelo amor e carinho durante estes anos de estudos, os quais também demandaram muita compreensão.

Agradeço imensamente ao prof. Dr. Raul Alemida Júnior, pela orientação neste trabalho durante todo o curso de Mestrado. Seu exemplo de cuidado, atenção e disponibilidade para discutir me inspiram e cultivam o grande respeito pelo qual tenho a este profissional.

Agradeço aos meus amigos de faculdade, os quais sempre me apoiaram e dedicaram palavras de estímulo em momentos de dificuldades, em especial, merecem menção: Pedro Jorge Freire, Diego de Moura, Paulo André, Eronides Neto e Lucas Araújo. Também destino palavras de agradecimentos a José Romildo Mendes por ter contribuído na participação dos resultados aqui expostos.

Agradeço aos meus parceiros de trabalho, em especial, Wagner Santiago, Kaio Wesley e Diego Rocha, pelo companheirismo e encorajamento nas batalhas diárias. Por fim, agradeço ao meu supervisor, Sérgio Romero, pelo incentivo e por me ajudar a alcançar minhas metas.

Agradeço, por fim, ao CNPq e à Pró-Reitoria de Pesquisa e Pós-graduação pelo auxílio financeiro durante os primeiros meses de Mestrado, e ao Programa de Pós-graduação em Engenharia Elétrica da UFPE pela oportunidade concedida.

## RESUMO

Redes ópticas elásticas oferecem uma solução promissora ao desafio de alocação adaptativa de recursos de acordo com as demandas vigentes de comunicação. Em tempos em que a conectividade impera, a não-restrição aos tradicionais 50GHz a que canais ópticos estão submetidos (em redes WDM) também impõe diversidade nas formas em que interações físicas não-lineares se manifestam em novas composições de arranjos espectrais. Movida pela elaboração de modelos matemáticos de propagação não-linear com baixa complexidade computacional, a busca pela fidelidade de reprodução de efeitos de camada física amplia o campo de análise em simulações de redes e permite avanço em otimizações que garantam QoT. Adicionalmente, a penetração de técnicas de Inteligência Artificial em aplicações de engenharia permite uma investigação eficiente (quando comparada a técnicas tradicionais de programação matemática) de dois problemas específicos na busca de mitigação das imperfeições físicas, o de determinação de perfis de potência e de alocação espectral. Neste contexto, o presente trabalho estuda a aplicação de duas técnicas de otimização baseadas em Inteligência Artificial: otimização por enxame de partículas e algoritmo genético, traçando um paralelo entre características biológicas com o enredo de transmissão óptica na tentativa de prover diversidade em perfis que atendam de forma apropriada as circunstâncias encontradas em redes de comunicação. Por fim, o contraste entre as duas meta-heurísticas propõe no algoritmo genético uma candidatura favorável na tratativa dos modelos não-lineares discutidos, por apresentar eficácia satisfatória quando comparado a recursos matemáticos amplamente utilizados. Além disso, a concordância com resultados científicos publicados e a possibilidade de análises de compromisso multiobjetivas, elencam o algoritmo genético com forte credibilidade para tratativas de otimização no campo de transmissão óptica.

**Palavras-chave:** Redes ópticas elásticas. Não-linearidade. Otimização por enxame de partículas. Algoritmos genéticos.

## ABSTRACT

Elastic optical networks offer a promising solution to the challenge of adaptive allocation of resources according to the current demands of communication. In times when connectivity rules, no impediments to traditional 50GHz bandwidth in which optical channels are confined (in WDM networks) also imposes diversity in how nonlinear physical interactions manifest in new spectrum arrangement frameworks. Driven by the elaboration of nonlinear propagation mathematical models with low computational complexity, the search for fidelity on reproduction of physical layer effects expands the analysis field in network simulations and permits the advance in optimizations that guarantee QoT. In addition, the penetration of artificial intelligence techniques in engineering applications allows an efficient investigation (when compared to traditional mathematical programming techniques) of two specific problems in the search for mitigation of physical imperfections, which are the determination of launch power profiles and spectral allocation. In this context, the present work studies the application of two evolutionary optimization techniques: particle swarm optimization and genetic algorithm, drawing a parallel between biological features and the optical transmission plot in an attempt to provide diversity in profiles that properly meet the circumstances found in communication networks. Finally, the contrast between the two meta-heuristics proposes in genetic algorithm a favorable application in the approach of the nonlinear models discussed for having satisfactory efficiency when compared to widely used mathematical techniques. Besides, the agreement with published scientific results and the possibility of multi-objective compromise analysis, empower genetic algorithm with strong credibility for optimization studies in the field of optical transmission.

**Keywords:** Elastic optical networks. Nonlinearity. Particle swarm optimization. Genetic algorithms.



## LISTA DE FIGURAS

Figura 1 – Exemplo de como canais ópticos podem interagir mutuamente. O fruto desta interação manifesta-se através de ruído não-linear que pode ser auto-gerado (SCI) ou advindo de influência externa (XCI). . . . .	21
Figura 2 – Estrutura de link óptico utilizada no modelamento de propagação de canais deste trabalho. . . . .	22
Figura 3 – Comportamento aditivo do ruído ASE e da não-linearidade ao longo da fibra	25
Figura 4 – Esquema representando a diferença entre canais ópticos WDM e elásticos. .	26
Figura 5 – Uma perspectiva gráfica do PSO. Partículas (pássaros) posicionadas geograficamente na $l$ -ésima iteração. . . . .	29
Figura 6 – Deslocamento de um determinado ponto $\zeta_i^l$ para $\zeta_i^{l+1}$ e demais variável envolvidas. . . . .	31
Figura 7 – Um analogia introdutória para tríade de canais ópticos conjugados. . . . .	33
Figura 8 – Rede WDM para comparação de modelos físicos e técnicas matemáticas de otimização. . . . .	35
Figura 9 – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando todos canais possuem mesma potência. . .	36
Figura 10 – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando o regime de potência agrupada é investigado.	37
Figura 11 – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando o regime de potência otimizada individualmente aliada à reorganização espectral ótima é investigada. . . . .	38
Figura 12 – Comportamento dos três regimes quando a ocupação da rede é levada em consideração . . . . .	39
Figura 13 – Comportamento dos três regimes quando o comprimento do primeiro <i>hop</i> da rede é levado em consideração . . . . .	39
Figura 14 – Exemplo de como aumentar a taxa total transmitida sem comprometer QoT.	40
Figura 15 – Diagrama de fluxo básico para entendimento do GA. . . . .	43
Figura 16 – Comparação entre cromossomo e conjunto de canais ópticos transmitidos em fibra. . . . .	45
Figura 17 – Mecanismos de cruzamento (I.a e I.b) e Mutação (II.a e II.b) em conjunto de canais ópticos elásticos. . . . .	46
Figura 18 – (a) Ilustração da curva de Pareto e distribuição dos indivíduos. (b) Relações de dominância em referência ao indivíduo $j$ . . . . .	47
Figura 19 – Representação gráfica do <i>Hypervolume</i> para duas dimensões. . . . .	49
Figura 20 – Espaçamento espectral para a condição de não-sobreposição dos canais. . .	51

Figura 21 – Perfil de densidade espectral de potência e arranjo espectral ótimo para formulação MINLP. . . . .	53
Figura 22 – Frentes de Pareto para otimização: banda x mínima margem de OSNR. . . .	54
Figura 23 – (a) Indivíduo que prioriza mínima margem. (b) Indivíduo com perfil interme- diário. (c) Indivíduo que prioriza banda. . . . .	55
Figura 24 – Frentes de Pareto para otimização: banda x soma das margens de OSNR. . .	56
Figura 25 – (a) Indivíduo que prioriza soma das margens. (b) Indivíduo que prioriza banda.	57
Figura 26 – Evolução das frentes de Pareto com o número de iterações. . . . .	58
Figura 27 – (a) Comparação NSGA-II sob perspectiva 1. (b) Comparação NSGA-II sob perspectiva 2. . . . .	60
Figura 28 – Evolução das frentes de Pareto para NSGA-II proposto (Perspectiva 1). . . .	62
Figura 29 – Indivíduo que prioriza banda. . . . .	63
Figura 30 – Indivíduo que prioriza mínima margem. . . . .	63
Figura 31 – Comparação entre NSGA e NSGA-II Proposto (Perspectiva 1). . . . .	64
Figura 32 – Comparação entre NSGA e NSGA-II Proposto (Perspectiva 2). . . . .	64

## LISTA DE SÍMBOLOS

$\gamma$	Coefficiente de não-linearidade da fibra.
$\alpha$	Coefficiente de atenuação da fibra.
$\beta_2$	Coefficiente de dispersão cromática de segunda ordem.
$L$	Comprimento da fibra.
$P_o$	Potência emitida por amplificador óptico.
$P_i$	Potência de entrada em amplificador óptico.
$N_s$	Número de seções ( <i>spans</i> ).
$h$	Constante de Planck.
$F_s$	Figura de ruído do amplificador.
$\nu_0$	Frequência central do canal.
$\Gamma$	Ganho do Amplificador.
$G_{ASE_i}$	Densidade espectral de potência do ruído ASE do canal $i$ .
$G_{NLI_i}$	Densidade espectral de potência do ruído não-linear do canal $i$ .
$\zeta_i^l$	Identificador do indivíduo de ordem $i$ na $l$ -ésima iteração. No enredo de otimização por enxame de partículas significa a posição geométrica que este pode assumir. Já para algoritmo genéticos, representa a característica resultante do arranjo de determinados genes.
$\zeta_{PBest,i}$	Identificador da melhor posição geométrica (em termos de uma função objetivo ) experimentada por uma partícula $i$ .
$\zeta_{GBest}$	Identificador da melhor posição geométrica (em termos de uma função objetivo ) experimentada por algum indivíduo dentro do enxame.
$f_{Obj}$	Função objetivo.
$\mathbf{g}_{prev}$	Conjunto de melhores posições visitadas pelas partículas do enxame.
$\mathbf{p}_{prev,i}$	Conjunto de posições visitadas pela partícula $i$ .
$\sigma_i$	Velocidade da partícula $i$ .

$k_1$	Escalar cognitivo.
$k_2$	Escalar social.
$k_3$	Coefficiente de inércia.
$Pr_C$	Probabilidade de cruzamento.
$Pr_M$	Probabilidade de mutação.
$g_{d,i}$	Grau de dominância da partícula $i$ .
$V_i$	Hypervolume da partícula $i$ .
$u$	Limite superior da frequência do último canal do espectro.
$t_i$	Inverso da OSNR do canal de ordem $i$ .
$E$	Conjunto de links da rede.
$D$	Conjunto de canais que compõem o espectro.
$K_{l,j}$	Espaçamento espectral entre dois canais vizinhos.
$c_i$	Eficiência espectral do canal de ordem $i$ .

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>14</b>
<b>2</b>	<b>UMA INTRODUÇÃO A CONCEITOS DE COMUNICAÇÕES ÓPTICAS E MODELOS DE PROPAGAÇÃO NÃO-LINEAR . . . . .</b>	<b>18</b>
<b>2.1</b>	<b>Uma breve visão histórica e conceitual . . . . .</b>	<b>18</b>
<b>2.2</b>	<b>Propagação eletromagnética . . . . .</b>	<b>19</b>
2.2.1	Atenuação na Fibra . . . . .	19
2.2.2	Efeitos não-lineares . . . . .	20
<b>2.3</b>	<b>Investigação de modelos não-lineares . . . . .</b>	<b>20</b>
<b>2.4</b>	<b>Redes ópticas elásticas . . . . .</b>	<b>25</b>
<b>3</b>	<b>OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS NA DETERMINAÇÃO DE PERFIS DE POTÊNCIA . . . . .</b>	<b>28</b>
<b>3.1</b>	<b>Uma abordagem conceitual da técnica . . . . .</b>	<b>28</b>
<b>3.2</b>	<b>Adaptação para um cenário de transmissão . . . . .</b>	<b>32</b>
<b>3.3</b>	<b>Uma alternativa para técnicas de otimização tradicionais . . . . .</b>	<b>33</b>
3.3.1	Modelo de canais com potência constante . . . . .	34
3.3.2	Modelo de canais com potência agrupada . . . . .	36
3.3.3	Modelo de canais com potência otimizada individualmente . . . . .	37
<b>3.4</b>	<b>Uma análise adicional . . . . .</b>	<b>38</b>
<b>4</b>	<b>ALGORITMO GENÉTICO COMO SOLUCIONADOR DE OTIMIZAÇÃO DISCRETA EM CANAIS ÓPTICOS ELÁSTICOS . . . . .</b>	<b>41</b>
<b>4.1</b>	<b>Conhecendo um pouco da história da meta-heurística . . . . .</b>	<b>41</b>
<b>4.2</b>	<b>Detalhando a técnica . . . . .</b>	<b>43</b>
4.2.1	Geração de população inicial . . . . .	43
4.2.2	Cruzamento . . . . .	44
4.2.3	Mutação . . . . .	45
4.2.4	Elitismo . . . . .	46
<b>4.3</b>	<b>NSGA-II . . . . .</b>	<b>46</b>
4.3.1	<i>Fast Non-Dominated Sorting</i> . . . . .	48
4.3.2	<i>Crowding Distance</i> . . . . .	48
<b>4.4</b>	<b>Uma perspectiva para tratamentos tradicionais . . . . .</b>	<b>50</b>
<b>4.5</b>	<b>GA como ferramenta de otimização . . . . .</b>	<b>53</b>
<b>4.6</b>	<b>Otimizando o arranjo espectral . . . . .</b>	<b>61</b>

<b>5</b>	<b>CONCLUSÃO</b> . . . . .	<b>66</b>
<b>5.1</b>	<b>Trabalhos futuros</b> . . . . .	<b>66</b>
<b>5.2</b>	<b>Trabalhos publicados</b> . . . . .	<b>67</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>68</b>
	<b>APÊNDICE A – UM EXEMPLO DE APLICAÇÃO DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS</b> . . . . .	<b>70</b>
	<b>APÊNDICE B – APLICANDO O ALGORITMO GENÉTICO</b> . . . . .	<b>72</b>

## 1 INTRODUÇÃO

A dinamicidade das demandas atuais de tráfego de dados tem promovido o desenvolvimento das redes de infraestrutura de internet com crescimento vertiginoso e expectativas espantosas para as próximas décadas. Em tempos em que o *e-commerce* é vital para o empoderamento dos negócios, que o entretenimento sob demanda alavanca o sucesso de plataformas de *streaming* de vídeo e quando o IoT<sup>1</sup> impõe o rumo da conectividade para praticamente qualquer coisa, a necessidade de aprimoramento dos recursos de tecnologia de transmissão é colocada em cheque.

Segundo pesquisa levantada pela Cisco, até 2021 o tráfego global de dados móveis alcançará 587 exabytes por ano, sendo o Brasil responsável por 1,6% deste quantitativo (9,4 exabytes/ano). Dados da Anatel mostram que, em dois anos, entre 2015 e 2017, o total de acessos mensais por meio de fibra saltou mais de 630%, de 128 mil para 936 mil entre os provedores. Estes indicadores testemunham o robustecimento que as redes de infraestrutura de dados, progressivamente dominadas por tecnologias ópticas, têm experimentado. Desta forma, com a heterogeneidade de topologias, demandas de tráfego e infraestrutura física, a *qualidade de transmissão* (referido doravante pelo acrônimo QoT, do inglês *quality of transmission*) torna-se um objeto de estudo protagonista nos critérios de decisão para planejamento de redes ópticas, reforçando, assim, a relevância que o tratamento de camada física ministra na arquitetura de alocação espectral.

Seguindo as tendências de versatilidade na utilização eficiente de espectro, vê-se nas redes ópticas elásticas (*flexible-grid networks*, como mais comumente referenciadas em inglês) um aliado auspicioso para atender os futuros cenários de demandas de tráfego. Estes cenários caracterizam-se pela presença de *transponders*<sup>2</sup> de banda variável construindo perfis de alocação que garantam redução de bloqueio. Redução esta que comumente é alcançada através da gerência da perda de capacidade em enlaces. Para isto, heurísticas de alocação de espectro vastamente usadas na literatura (e.g., *First-fit*) concentram-se em garantir otimização no posicionamento de canais ópticos em virtude de maximizar critérios lógicos (camada de rede). Contudo, ainda é recente a discussão do impacto físico que estes métodos tradicionais implicam à QoT.

Dentre os principais candidatos a fatores físicos impactantes, está a não-linearidade. Consequente do efeito *Kerr*, este fenômeno manifesta-se através de ruído aditivo (aproximado por perfil gaussiano) caracterizado pela interação intra/inter-canal de portadoras ópticas. Seu modelamento matemático é um desafio que tem concebido diversidade de material científico desde o início da década de noventa (SPLETT; KURZKE; PETERMANN, 1993). Por ser

<sup>1</sup> Acrônimo de *Internet of things*, utilizado para se referir a conceito que prevê conectividade em objetos através de tecnologia embarcada.

<sup>2</sup> Dispositivos transmissores presentes em redes ópticas.

uma solução da equação não-linear de Schrödinger, métodos que viabilizam a simplificação matemática e sua aplicação fomentam pesquisas por proporcionarem uma aproximação aceitável com reduzido processamento computacional. Neste campo de estudos, um modelo desenvolvido em 2014 (POGGIOLINI et al., 2014) se destaca com êxito. Este trabalho propõe-se em tratar o ruído gerado na propagação da luz como a soma de uma parcela de comportamento linear e originada nos amplificadores ópticos (EDFAs) e outra não-linear, devido a propriedades físicas da fibra em questão. Esta última subdivide-se em uma parcela gerada unicamente pelo próprio canal (SCI - *Self-channel Interference*) e outra que considera o cenário de ocupação das conexões vizinhas (XCI - *Cross-channel Interference*).

A partir do conhecimento matemático do modelo exposto, é imediata a percepção de que a alocação espectral influencia diretamente nos valores de ruído por canal de forma que requisições centrais apresentam  $G_{NLI}$  (densidade espectral de potência de interferência não-linear) mais alta devido à exposição bilateral aos canais vizinhos. Por outro lado, canais alocados mais próximos aos extremos do espectro são menos vulneráveis à ação de interferência intercanal e, por conseguinte, sofrem menos devido às penalidades não-lineares (NAKASHIMA et al., 2015). Este problema tem sido superficialmente atacado por técnicas que garantem QoT através da permissão de folga substancial de margem de OSNR (KLEKAMP; DISCHLER; BUCHALI, 2011) para canais operarem sem erro nos piores casos, o que causa uma utilização ineficiente de recursos.

Alocações de recursos em redes elásticas têm sido propostas em cenários em que variáveis como potência e banda são otimizadas separadamente (PALKOPOULOU et al., 2013; J.ZHAO; H.WYMEERSCH; E.AGRELL, 2015). No entanto, essas abordagens não usam com plenitude as vantagens das redes elásticas e apenas dão fruto a soluções sub-ótimas, fazendo-se necessário o tratamento conjunto de potência e banda. Uma indagação natural surge quando entra em foco a natureza das técnicas de otimização para lidar com um problema não-linear com conjuntos de variáveis discretas e contínuas. Técnicas tradicionais de programação matemática (YAN et al., 2015) são imediatamente pensadas pela acurácia e variedade de softwares genéricos que se propõem em implementá-las. Todavia, em um universo em que a quantidade de canais ópticos permeia dezenas, com valores de potência e banda podendo variar extensamente dentro de intervalos e sujeitos à multiplicidade de níveis de modulação, recorrer a métodos de otimização não-tradicionais desponta como uma alternativa atrativa.

Devido ao contínuo esforço e enfoque que é dado a técnicas de Inteligência Artificial na resolução de problemas em diversas áreas da ciência, vê-se na adaptabilidade dos métodos evolucionários promissora opção para o problema de alocação de espectro e determinação de potência visando comedir efeitos indesejáveis de camada física em canais ópticos. Apesar da natureza estocástica, estas técnicas buscam diversidade de soluções que iterativamente se aproximam do ótimo, dando, assim, possibilidade de uma análise mais profusa de resultados. Ainda, a chance de avaliações multiobjetivas elevam estas técnicas a candidatos mais apropriados



dentro do contexto de redes, em que recursos são apropriadamente escolhidos quando sob a análise de relações de compromisso. Para estudo, este trabalho baseou-se na aplicação de duas técnicas evolucionárias. A primeira, *otimização por enxame de partículas* (em inglês referenciado por *particle swarm optimization*, ou PSO), recorre ao modelamento matemático primeiramente estudado no movimento de pássaros mas que também se manifesta em demais conjuntos populacionais na natureza. Nesta, a posição assumida por cada indivíduo é atualizada de forma iterativa dependendo de posições experimentadas anteriormente e da influência do grupo. A segunda, *algoritmo genético* (de acrônimo GA), reproduz o processo de mutação e cruzamento de cromossomos na geração de indivíduos que são iterativamente escolhidos por se amoldarem com mais facilidade às condições ambiente (o que melhor atende a uma função objetivo).

No PSO, o processo de atualização de posição do  $i$ -ésimo indivíduo na iteração de ordem  $l$  ( $\zeta_i^l$ ) se baseia na combinação linear entre sua posição anterior ( $\zeta_i^{l-1}$ ), a melhor posição experimentada por este ( $\zeta_{PBest,i}$ ) e a melhor posição global, ou seja, experimentada pelo conjunto ( $\zeta_{GBest}$ ). Assim, este método varre um espaço de soluções de forma contínua e, logo, é apropriado para problemas em que não haja restrição de uso exclusivo de variáveis discretas. Isto resolve os objetivos deste trabalho de forma parcial, visto que o problema de alocação e arranjo espectral é basicamente uma atividade que recorre a variáveis discretas. Por outro lado, é possível chegar a valores de potência por canal com maior precisão, visto que esta é uma tarefa de natureza contínua.

No sentido contrário ao proposto pelo PSO, o GA varre um espaço de soluções com passos discretos. Devido a sua natureza comparativa com genes (unidade fundamental da hereditariedade), a adaptabilidade deste método quanto à questão de alocação espectral (essência discreta) é mais eficiente. Adicionalmente, o fato de permitir a discretização de variáveis outrora contínuas no PSO, conta positivamente na consolidação deste como forte candidato ao objetivo final deste estudo. Ressalta-se, porém, que esta opção impõe um custo em convergência e acurácia ao tentar reproduzir valores contínuos através de passos amostrados.

Com estas motivações, o presente trabalho tem por objetivos:

- realizar um estudo detalhado sobre a aplicação de modelos matemáticos de propagação não-linear para canais ópticos elásticos em redes ponto-a-ponto.
- descrever e analisar o impacto que o uso de *otimização por enxame de partículas* (PSO) tem no enredo de transmissão óptica ao buscar perfis de lançamento de potência que mitigam efeitos não-lineares.
- investigar a utilização de *algoritmos genéticos* (GA) suprimindo não somente o problema de determinação de perfis otimizados de potências de lançamento mas também de arranjo espectral que garantam QoT sob análises multiobjetivas.

Com a finalidade de concentrar este estudo na obtenção de perfis espectrais e de potência para posteriormente serem usados em simulações de redes ópticas dinâmicas, o presente trabalho

focou suas energias em uma análise essencialmente de transmissão óptica. A abundância de pontos a serem explorados no contexto de camada física absorveu considerável parte dos esforços para serem discutidos sob abordagens de redes ponto-a-ponto (e.g., *Tandem*). Isso permitiu comparar os resultados aqui apresentados com tratamentos semelhantes encontrados na literatura.

A dissertação divide-se como segue. O Capítulo 2 revisa brevemente conceitos de redes ópticas e abre espaço para expor modelos matemáticos de propagação não-linear que servem de alicerce para este trabalho. O Capítulo 3 esforça-se em contextualizar a utilização do PSO na procura por perfis de lançamento de potência que maximizem a mínima margem de OSNR como meio de garantir QoT. No capítulo 4, discute-se a aplicação do GA suprimindo as restrições deixadas pelo PSO em uma otimização multiobjetiva que entrega um perfil de alocação espectral e de determinação de potência, de forma conjunta. No capítulo 5, por fim, são elencadas algumas alternativas de trabalhos futuros e conclusões deste estudo.

Ao fim, é válido mencionar, caso haja o interesse em reproductibilidade dos testes, que a ferramenta utilizada na obtenção dos resultados deste trabalho é uma versão modificada do simulador de redes ópticas SIMTON (CHAVES; PEREIRA; MARTINS, 2010). Esta ferramenta foi alterada para incluir os modelos de camada física bem como os códigos de otimização evolucionária criados pelo próprio autor. Todas as imagens ilustrativas apresentadas neste trabalho (com exceção da Fig. 4) foram também de elaboração do autor, o qual utilizou do software *inkscape*. Os gráficos criados utilizaram dos pacotes PGF e Tikz ( $\text{\LaTeX}$ ) e Matplotlib (Python)

## 2 UMA INTRODUÇÃO A CONCEITOS DE COMUNICAÇÕES ÓPTICAS E MODELOS DE PROPAGAÇÃO NÃO-LINEAR

Neste capítulo, uma breve apresentação será feita sobre os conceitos básicos que coordenam o funcionamento de um sistema de comunicação óptica. Serão expostos modelos para caracterizar a propagação da luz em fibra, bem como o enredo destes princípios no contexto de telecomunicações. Em um primeiro momento, também será discutido o problema das imperfeições de camada física, oriundas de efeitos não-lineares, e que desempenham papel crítico no diagnóstico de QoT em redes de comunicação óptica. Após esta primeira abordagem, o foco será voltado para a teoria de canais ópticos elásticos como uma solução para os questionamentos que limitam as tecnologias e demandas de transmissão atuais.

### 2.1 Uma breve visão histórica e conceitual

A popularização das fibras ópticas, atualmente, disfarça a antiguidade desta tecnologia. Demonstrações sobre como transmitir luz por meio de refração foram feitas em 1840, em Paris, pelos cientistas Daniel Colladon e Jacques Babinet. Já no fim do século 19, o conceito de refração era amplamente utilizado para diagnóstico de problemas estomacais. Todavia, aplicações mais práticas (e.g., transmissão de imagens) só vieram após o ano de 1952, quando o físico indiano Narinder Singh Kapany realizou um experimento que culminou na descoberta da fibra óptica. Após isso, inúmeros experimentos foram implementados com o intuito de aprimorar este material como meio de transmissão e inovar na sua aplicação. Em 1970, os cientistas da *Corning Inc.*, Drs. Robert Maurer, Donald Keck e Peter Schultz, transporam um dos grandes desafios da época, que era fabricar uma fibra com atenuação inferior a 1%. Desde então, pesquisas nesta área têm evoluído e hoje já alcançam-se os limites teóricos.

Atualmente, devido à difusão da tecnologia da informação, a fibra se tornou a solução perfeita para transmissão de dados em razão de:

- facilidade de utilizar infraestruturas existentes,
- não sofrer com interferências eletromagnéticas,
- permitir integridade do sinal por longas distâncias, quando comparada a cabos de cobre.

Logo, testemunhando a relevância desta tecnologia no mundo moderno, é crucial entender apropriadamente os conceitos e princípios que permeiam as comunicações ópticas e que idealizam a construção deste estudo.

## 2.2 Propagação eletromagnética

O estudo da propagação da luz, em termos de teoria clássica, é famosamente resumido a seguinte equação de onda:

$$\nabla^2 E + n^2(w)k_0^2 E = 0 . \quad (2.1)$$

No entanto, é em (AGRAWAL, 2002) que existe a reformulação da Equação 2.1 para um ambiente mais personalizado a operar no contexto de comunicações óptica. Esta reformulação utiliza da equação de Manakov e contempla três problemas intrínsecos da fibra óptica: dispersão cromática, atenuação e efeitos não-lineares. Assim, a equação de onda é reescrita da seguinte forma:

$$\frac{\partial a}{\partial z} = i\gamma \|a\|^2 a - i\frac{\beta_2}{2} \frac{\partial^2 a}{\partial t^2} - \frac{\alpha}{2} a , \quad (2.2)$$

onde,  $a = [a_x a_y]^T$  são os dois componentes de polarização do campo óptico,  $\gamma$  é o coeficiente não-linear,  $a$  representa a potência óptica,  $\beta_2$  é o coeficiente de dispersão cromática de segunda ordem,  $\alpha$  é o coeficiente de atenuação da fibra,  $z$  é a distância de propagação e  $t$  é a coordenada tempo.

O problema da dispersão possui como solução mitigatória do seu efeito o uso de fibras com dispersão deslocada. Isto praticamente elimina este efeito em guias de onda na terceira janela de transmissão (1550 nm). Além disso, considera-se que as consequências de outros tipos de dispersão já são solucionadas com códigos corretores e processamento digital de sinais. Os outros dois problemas serão detalhados a seguir.

### 2.2.1 Atenuação na Fibra

As perdas na fibra representam um fator limitante, pois elas reduzem a potência do sinal nos receptores, os quais têm um limite mínimo de nível de recepção para recuperar a informação com precisão. Assim, uma distância máxima de transmissão pode ser projetada tendo como limitante a potência mínima de recepção.

O parâmetro que caracteriza a perda na fibra é o coeficiente de atenuação ( $\alpha$ ), que se relaciona com as potências de entrada ( $P_i$ ) e saída ( $P_o$ ) de uma seção óptica (*span*) de comprimento  $L$ , a partir de:

$$P_o = P_i e^{-\alpha L} , \quad (2.3)$$

onde  $\alpha$  é expresso em  $[\text{km}^{-1}]$ . O leitor questionará quais efeitos intrínsecos que causam essa perda na potência, de onde é possível extrair os dois mais importantes: espalhamento de *Rayleigh* e as perdas por absorção do material.

As perdas por absorção são mecanismos de atenuação relacionados à composição do material, impurezas e ao processo de fabricação da fibra, do qual resulta a dissipação de uma potência óptica na forma de calor. Já as perdas pelo espalhamento de *Rayleigh* são causadas por variações microscópicas na densidade do material da fibra, de flutuações na sua composição ou de defeitos estruturais provenientes do processo de fabricação. Esses efeitos originam variações no índice de refração que, por sua vez, provoca um espalhamento da luz. Esse espalhamento é proporcional a  $\lambda^{-4}$  e reduz-se drasticamente com o aumento do comprimento de onda (AGRAWAL, 2002).

### 2.2.2 Efeitos não-lineares

Para taxas de transmissão mais elevadas do que 10 Gbps e altas potências de transmissão (superior a 1 mW), os efeitos não-lineares começam a impor um papel não negligenciável (MECOZZI; IANNONE; MATERA, 1998). Estes efeitos se subdividem em duas categorias. A primeira aparece devido à interação entre o feixe de luz e a vibração molecular do vidro. Os dois efeitos mais importantes dessa categoria são: o *Stimulated Brillouin Scattering* (SBS) e *Stimulated Raman Scattering* (SRS). A segunda categoria, e mais importante para este trabalho, aparece devido à dependência do índice de refração com a intensidade do campo elétrico. A interação entre o campo elétrico e o dielétrico resulta em uma modulação. Esta modulação é uma função não-linear do campo de entrada. Esse fenômeno é mais conhecido como efeito *Kerr* e é o responsável pela interferência não-linear em sistemas de comunicação óptica.

Na Equação , o efeito *Kerr* é representado pelo coeficiente não-linear da fibra,  $\gamma$ , que é definido por:

$$\gamma = \frac{n_2 \omega_c}{c A_{eff}}, \quad (2.4)$$

onde  $n_2$  é o índice não-linear de refração,  $\omega_c = 2\pi f_c$  é a frequência angular da portadora,  $c$  é a velocidade da luz e  $A_{eff}$  é a área efetiva da fibra.


A interferência não linear pode ser entendida como a soma de três efeitos: *self-phase modulation* (SPM), *cross-phase modulation* (XPM) e o *four-wave mixing* (FWM).

## 2.3 Investigação de modelos não-lineares

Para discussão dos efeitos não-lineares que este trabalho deseja tratar, é preciso entender um pouco mais os detalhes da SPM e XPM.

A SPM é o efeito não-linear derivado da influência que a intensidade do próprio canal, ou feixe óptico, causa em si mesmo, mudando sua fase óptica pelo efeito *Kerr*. Isto pode ser descrito como uma mudança não-linear no índice de refração, o que causa uma fase induzida que é proporcional à intensidade do pulso. Portanto, diferentes partes do pulso propagam com

**Figura 1** – Exemplo de como canais ópticos podem interagir mutuamente. O fruto desta interação manifesta-se através de ruído não-linear que pode ser auto-gerado (SCI) ou advindo de influência externa (XCI).



diferentes fases, o que aumenta os efeitos degradativos do sinal, semelhantemente ao efeito de dispersão cromática. Esse efeito é mais intenso quando usado para altas potências e é ainda mais relevante para sistemas com alta taxa de transmissão. A partir de agora, receberá a nomenclatura: SCI - *self-channel interference*, para que permaneça a concordância com a literatura.

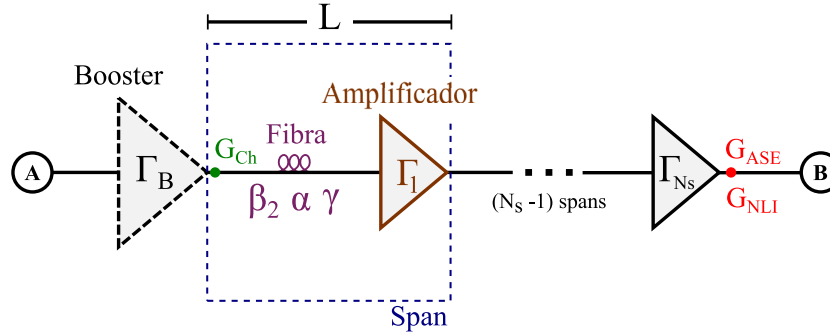
Quanto ao XPM, é o efeito não-linear resultado da interação mútua entre canais com diferentes frequências portadora, diferentes taxas de transmissão e diferentes velocidades de grupo compartilhando o mesmo caminho óptico. Assim, há a geração de uma mudança na fase óptica pelo efeito *Kerr*. Desta forma, é possível entender o XPM como um fenômeno que basicamente converte a flutuação de potência, de um determinado comprimento de onda, em uma flutuação de fase sobre outro comprimento que está sendo co-propagado. Procedendo com a mesma política, a nomenclatura deste efeito será alterada para XCI-*cross-channel interference*. A Fig. 1 exemplifica esta interação entre os canais ópticos que preenchem o espectro.

A indagação agora é: como modelar estes efeitos dentro de um cenário de transmissão óptica? Para isto, o leitor precisa conhecer previamente a estrutura de link óptico utilizada neste trabalho e também ilustrada a partir da Fig. 2.

Para sinais se propagarem por longas distâncias faz-se necessário o uso de amplificadores para compensar as perdas ao longo da transmissão. A principal função destes é amplificar o sinal óptico diretamente, sem exigir sua conversão para o domínio elétrico. Amplificadores são uma parte importante do sistema de comunicação, pois são os componentes que mais consomem potência e também adicionam ruído à rede. No estudo aqui realizado, foi usado um amplificador de fibra dopada com érbio, mais conhecido como EDFA, o qual é a tecnologia dominante usada em sistemas de comunicação por fibra óptica.

Outro aspecto importante em um amplificador, brevemente mencionado, é o ruído que ele adiciona ao sistema. Em um EDFA, por exemplo, o ruído é inserido ao sinal através de emissão espontânea e finalmente amplificado pelo processo de emissão estimulada, que leva à geração do que se conhece por ruído ASE (*Amplified Stimulated Emission*). Em um sistema

**Figura 2** – Estrutura de link óptico utilizada no modelamento de propagação de canais deste trabalho.



Fonte: o autor.

típico, o ASE não tem impacto relevante sobre o consumo de energia dos amplificadores, mas tem um impacto profundo na qualidade do sinal. Qualquer ruído adicionado ao sinal permanece com ele desde o momento da sua adição até a chegada ao receptor. Posteriormente, é amplificado em conjunto com o sinal por qualquer amplificador subsequente. Esse fato torna o ruído ASE um dos principais fatores limitantes de alcance de transmissão.

Num contexto de rede, considerando que cada link  $i$  tem  $N_s$  spans com mesmas características e que um canal percorre  $N_l$  links da sua origem até o seu destino, a densidade espectral do ruído ASE para esse canal pode ser descrita por:

$$G_{ASE_i} = \sum_{i=1}^{N_l} N_s h F_s \nu_0 (\Gamma_i - 1) \quad (2.5)$$

onde  $h$  é a constante de Plank,  $\Gamma$  é o ganho do amplificador,  $\nu_0$  é a frequência da portadora do sinal amplificado e  $F_s$  é o fator de ruído do amplificador.

Da mesma forma como foi feito o modelamento matemático para o ruído ASE, será realizado para a influência da XCI e SCI. Para isto, são utilizados dois desenvolvimentos amplamente difundidos no contexto de óptica não-linear e encontrados em (POGGIOLINI et al., 2014) e (JOHANNISSON; AGRELL, 2014). Estes trabalhos se baseiam no modelo gaussiano de aproximação do ruído. O modelo GN (do inglês, *Gaussian Noise*) é apenas um, dentre vários propostos ao longo dos anos, para descrever as perturbações não-lineares. Ele provou ser relativamente simples e, ao mesmo tempo, uma ferramenta confiável para previsão da não-linearidade em fibras em uma ampla gama de cenários.

Na construção da abordagem sob o regime do GN, algumas premissas são construídas, são elas:

- Considerar que a não-linearidade é relativamente baixa, sendo apenas uma perturbação

comparada com o sinal útil.

- A gaussianidade do sinal significa que o ruído se comporta como estacionário gaussiano. Esta suposição não é verificada no início da transmissão, mas, como o sinal se propaga ao longo de um link e fica completamente disperso, ele tende a assumir aproximadamente uma distribuição gaussiana.
- A perturbação do sinal gerada pela não linearidade (NLI) comporta-se como ruído gaussiano aditivo (AGN).

O raciocínio desenvolvido em (POGGIOLINI et al., 2014) leva à simplificação da densidade espectral de potência do ruído não-linear através de:

$$G_{NLI}(f) = \frac{16}{27} \gamma^2 L_{eff}^2 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} G(f_1)G(f_2)G(f_1 + f_2 - f) \cdot \rho(f_1, f_2, f) \chi(f_1, f_2, f) df_1 df_2 \quad (2.6)$$

onde o fator  $\rho$  da expressão pode ser entendido fisicamente como o quão eficiente é o batimento dos sinais na formação do FWM e  $\chi$  é o termo que representa o acúmulo da interferência não-linear ao longo dos múltiplos *spans* do link. A partir da Equação 2.6, uma série de manipulações matemáticas são derivadas para chegar a um modelo computacionalmente mais viável para o cálculo da  $G_{NLI}$ . Assim, é em (POGGIOLINI et al., 2014) que há uma apresentação analítica e consideravelmente resumida da influência não-linear em um canal  $i$  quando submetido à interação com um portadora  $n$  em termos de parâmetros de físicos. Esta relação é expressa por:

$$G_{NLI}(f_{ch,i}) = \frac{16}{27} \sum_{n_s=1}^{N_s} \gamma_{n_s}^2 L_{eff,n_s}^2 \cdot \prod_{k=1}^{n_s-1} \Gamma_{n_s}^3 e^{-6\alpha_{n_s} L_{s,n_s}} \cdot \prod_{k=n_s}^{N_s} \Gamma_{n_s} e^{-2\alpha_{n_s} L_{s,n_s}} \cdot \sum_{n=1}^{N_{ch}} G_{ch,n}^2 G_{ch,i} \cdot (2 - \delta_{n,i}) \cdot \psi_{n,i,n_s} \quad (2.7)$$

onde:

$$\psi_{n,i,n_s} \approx \frac{a \sinh(\pi^2 [2\alpha_{n_s}]^{-1} |\beta_{2,n_s}| [f_{ch,n} - f_{ch,i} + B_{ch,n}/2] B_{ch,i})}{4\pi (2\alpha_{n_s})^{-1} |\beta_{2,n_s}|} - \frac{a \sinh(\pi^2 [2\alpha_{n_s}]^{-1} |\beta_{2,n_s}| [f_{ch,n} - f_{ch,i} - B_{ch,n}/2] B_{ch,i})}{4\pi (2\alpha_{n_s})^{-1} |\beta_{2,n_s}|}, \quad (2.8)$$

$$n \neq i$$



$$\psi_{n,i,n_s} \approx \frac{\operatorname{asinh}\left(\frac{\pi^2}{2}[2\alpha_{n_s}]^{-1}|\beta_{2,n_s}|B_{ch,i}^2\right)}{2\pi(2\alpha_{n_s})^{-1}|\beta_{2,n_s}|}, \quad (2.9)$$

$$n = i.$$

Se o leitor investigar bem a formulação, verá que o segundo somatório da Equação 2.7 engloba o efeito auto-gerado (SCI) pelo canal  $i$  e o de influência advinda de canais vizinhos (XCI). O termo que classifica esta divisão é  $\psi_{n,i,n_s}$ . Neste, como é fácil identificar, existem as duas distinções. A primeira remete à influência externa ( $n \neq i$ ) sobre o canal  $i$ , ou seja, a XCI. Esta parcela do ruído não-linear depende unicamente do afastamento espectral entre as portadoras ( $f_{ch,n} - f_{ch,i}$ ), das bandas ( $B_{ch,i}$  e  $B_{ch,n}$ ) e, obviamente, da densidade espectral de potência de cada canal ( $G_{ch,n}$  e  $G_{ch,i}$ ). Já no segundo caso, isto é,  $n = i$  (SCI), fica claro que os agentes que influenciam a análise são a densidade espectral de potência do canal ( $G_{ch,i}$ ) e sua banda ( $B_{ch,i}$ ).

Em (POGGIOLINI et al., 2014), os ruídos ASE e NLI não são correlacionados. Como explicado anteriormente, o ruído não-linear (NLI) é assumido como sendo aproximadamente gaussiano e aditivo, semelhante ao ASE. Isto permite a soma incoerente dessas duas parcelas e, conseqüentemente, o cálculo da OSNR pode ser expresso por:

$$OSNR_i = \frac{G_{ch_i}}{G_{ASE_i} + G_{NLI_i}}. \quad (2.10)$$

Para que a análise fique mais fácil de se observar, ilustra-se a ação dos ruídos aqui discutidos ao longo da propagação por um link óptico na Fig. 3. Nesta figura, vê-se que o crescimento gradativo dos ruídos ASE e NLI (SCI + XCI) dá-se com a distância de propagação.

Por fim, a mesma abordagem de tratamento de ruído não-linear é feita em (JOHANNISSON; AGRELL, 2014). Neste, também há a preocupação em realizar a distinção entre as parcelas de interferência não-linear (SCI e XCI) como meio de simplificar ainda mais a formulação da Equação 2.7. Assim, segue que neste novo modelo a SCI e XCI são reformuladas por:

$$G_{SCI_i} = \frac{3\gamma^2}{\alpha^2} F_{i,i}^2 G_{ch,i}^3 N_s, \quad (2.11)$$

$$G_{XCI_i} = \frac{6\gamma^2}{\alpha^2} G_{ch,i} \sum_{n \in D} F_{i,n}^2 G_{ch,n}^2 N_s, \quad (2.12)$$

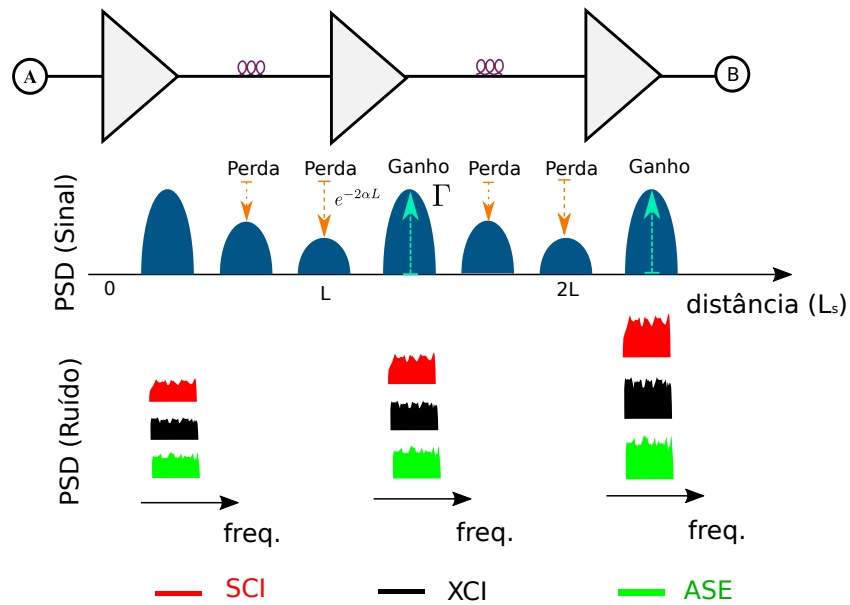
em que  $F_{ij}^2$  tem o mesmo papel de  $\psi_{n,i,n_s}$ , ou seja, de ser um fator de interação entre os canais e agora representado analiticamente através de:

$$F_{i,i}^2 \approx \frac{\alpha}{2\pi|\beta_2|} \operatorname{asinh}\left(\frac{\pi^2|\beta_2|\Delta f_i^2}{2\alpha}\right), \quad (2.13)$$

$$F_{i,n}^2 \approx \frac{\alpha}{4\pi|\beta_2|} \log\left(\frac{|f_i - f_n + \Delta f_n/2|}{|f_i - f_n - \Delta f_n/2|}\right), i \neq n. \quad (2.14)$$

Assim, é munido destes dois modelos que este trabalho propõe-se em estudar como a gerência de recursos de comunicação pode servir como um aliado na suavização de efeitos que comprometem a qualidade de transmissão em links ópticos.

**Figura 3** – Comportamento aditivo do ruído ASE e da não-linearidade ao longo da fibra



Fonte: Autor

Antes de finalizar esta etapa de fundamentação teórica, é crucial fazer uma breve introdução a conceitos de canais ópticos elásticos, os quais serão exhaustivamente abordados ao longo deste trabalho.


## 2.4 Redes ópticas elásticas

Com o crescente aumento na demanda por informação, em poucos anos se chegará ao limite das redes ópticas baseadas em WDM (Wavelength-division Multiplex). Por esse motivo, o conceito de redes ópticas elásticas tem sido alvo de pesquisa.

A EON (*elastic optical network*) possui a característica de dividir os recursos espectrais em slots de frequência na forma de subportadoras, permitindo múltiplos formatos de modulação com taxas de dados e espectro de tamanhos variados. Nesse contexto, o objetivo de uma EON é alocar uma demanda a um determinado caminho óptico que possua uma largura de banda com

um tamanho apropriado. A Figura 4 apresenta as diferenças entre a alocação de canais usando o conceito de grade fixa (WDM) e flexível (EON).

**Figura 4** – Esquema representando a diferença entre canais ópticos WDM e elásticos.



Fonte: Elastic Optical Networking: A New Dawn for the Optical Layer?

Na estratégia de grade fixa, a faixa de frequência do espectro utilizado é independente da demanda requisitada pelo cliente. Na grade flexível, essa faixa de frequência é adaptável de acordo com a demanda requisitada. Assim, um caminho óptico elástico pode transmitir múltiplas taxas de dados, pois seu tamanho é alocado de acordo com a demanda requisitada. Mas o que faz as redes elásticas serem tão almeçadas é o fato delas aproveitarem ao máximo o espectro, alocando de forma mais eficiente as requisições. Como pode ser observado na Fig. 4, o espectro para redes WDM é dividido em slots de 50 GHz. Isso faz com que, caso haja uma requisição que tenha uma banda de 10GHz, a rede desperdice 40 GHz. Já no caso da elástica, o espectro é dividido em slots de 12.5 GHz, ou menores, por exemplo até 3.175 GHz (YAN et al., 2015), o que faz com que essas perdas por espaços não-preenchidos caia drasticamente. Assim, como observado, mais canais conseguem ser transmitidos usando uma mesma seção do espectro óptico. Isto deve ser interpretado como uma otimização na utilização do espectro para um certo recurso definido.

A arquitetura da rede EON é composta por transmissores de largura de banda variável (BVT - *bandwidth-variable transponder*) e por comutadores ópticos de banda variável (ROADMs - *Reconfigurable Optical Add/Drop Multiplexer*) que permitem o estabelecimento de percursos com grade flexível.

Uma abordagem comumente utilizada pela literatura de redes ópticas elásticas define a distância de transmissão do caminho óptico como o fator mais relevante para QoT (JINNO et al., 2010). Portanto, a escolha do formato de modulação a ser utilizado é estabelecida de acordo com a distância do caminho percorrido na fibra. Dessa maneira, transmissões através de

caminhos ópticos mais curtos são capazes de utilizar níveis de modulação com maior eficiência espectral. Estes aspectos de adaptação de modulação para garantir qualidade na entrega da demanda motivam as discussões tratadas no Capítulo 3. No momento, esta apresentação breve servirá de embasamento para o leitor, o qual será exposto continuamente, e com detalhes, aos conceitos aqui comentados.

### 3 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS NA DETERMINAÇÃO DE PER- FIS DE POTÊNCIA

É no estudo de movimentos populacionais que o campo de otimizações evolucionárias encontra um precursor para modelamento matemático inspirado em comportamentos biológicos. Este capítulo versa sobre os conceitos basilares do PSO, brevemente apresentado na Introdução, bem como a aplicação deste no enredo de transmissão óptica para determinação de perfis de potência que suavizam penalidades advindas de efeitos não-lineares.

#### 3.1 Uma abordagem conceitual da técnica

Em meados do fim da década de oitenta e início dos anos noventa, estudos científicos voltados para aplicações de Inteligência Artificial começaram a concentrar atenção em modelos matemáticos que enforçavam-se em descrever movimentos sincronizados presentes na natureza, como por exemplo, no vôo de bando de pássaros e no nado de cardumes. Em 1987, o cientista Craig W. Reynolds (REYNOLDS, 1987), intrigado com a estética desses movimentos, descreveu *scripts* de simulações voltados para o campo de animação gráfica. A iniciativa buscava adicionar mais realidade ao trabalho de animadores no processo de criação. Três anos mais tarde, Frank Heppner (HEPPNER, 1990) divulgou trabalho que propôs tratar a nuance do movimento sincronizado de pássaros através de “*regras matemáticas*”. Estas regras obedeciam a equações diferenciais estocásticas regidas por fatores de regulação de velocidade, interação entre indivíduos e aleatoriedade. Este trabalho serviu de embasamento para o que mais tarde, em 1995, viesse a se firmar como a meta-heurística mais popular de movimento populacional.

No trabalho de James Kennedy e Russell Eberhart (KENNEDY; EBERHART, 1995), há a exposição de um método simples, “*implementável em poucas linhas de código*” (parafrazeando os autores) e que recorre a operadores matemáticos primitivos. De forma atraente, o método também exige pouca complexidade computacional (em termos de memória e processamento). O artigo publicado em 1995 trata da aplicação da técnica na otimização de funções não-lineares, o que converge com a proposta deste trabalho. Para o completo entendimento do processo de otimização, faz-se necessária a explicação dos conceitos fundamentais que permeiam o mesmo e expostos nos parágrafos a seguir.

Na dinâmica de movimentos populacionais, o universo de migração das partículas pode ser interpretado, matematicamente, como um espaço de possíveis soluções que cada uma destas pode assumir em determinado instante. Para entender com completude esta afirmação, suponha que, em um ambiente isolado (e.g., ilha), pássaros possam alçar vôos por entre as mais variadas áreas em busca de condições favoráveis à sobrevivência da espécie. Este ambiente é repleto de ecossistemas onde ora há fartura de recursos (ausência de predadores, água fresca e comida), ora há escassez dos mesmos, e a busca pela sobrevivência impõe a investigação de novas regiões

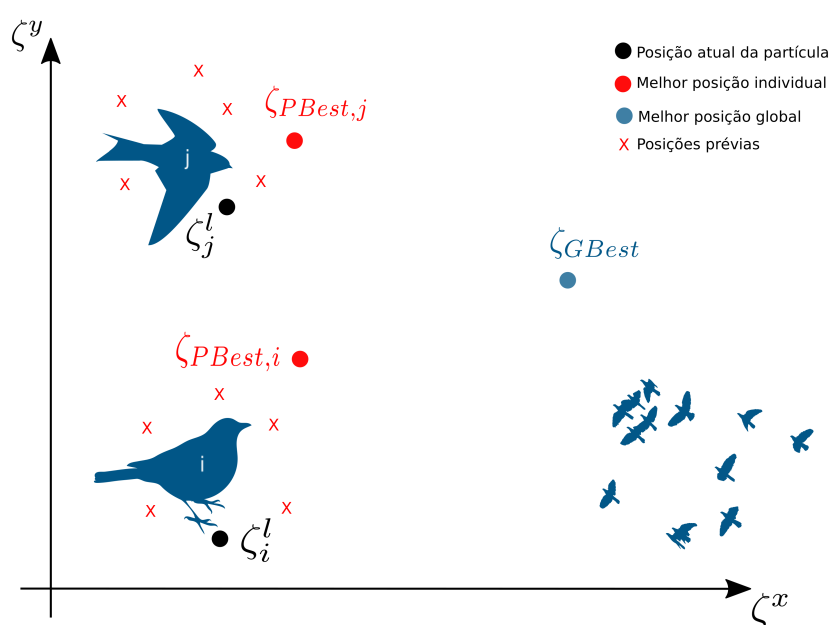
com abundância de proventos. Para facilitar a nomenclatura e a compreensão, deste momento em diante algumas referências precisam ser feitas, o que implica na analogia dos termos a seguir:

- **Pássaro:** Partícula ou indivíduo;
- **Bando:** Enxame;
- **Vôo:** Atualização da posição da partícula;
- **Intervalo de migração:** Iteração;

Cada partícula do enxame possui um registro de identificação, o que logicamente se expressa através de ordem numérica  $i$ . Assim, um conjunto de  $N$  partículas compõe um enxame, em que claramente  $1 \leq i \leq N$ . Por conseguinte, cada iteração de ordem  $l$  exemplifica o momento na linha cronológica do indivíduo em que uma migração foi concluída e este passou a assumir uma nova posição ( $\zeta^l$ ) no espaço ( $\zeta^l \in \mathbb{R}^n$ , por agora  $n = 2$ ). Resumindo o conceito construído, define-se a variável  $\zeta_i^l$  como a posição assumida pela partícula  $i$  ao início da  $l$ -ésima iteração.

O método apresentado por Kennedy e Eberhart afirma que, para uma partícula genérica migrar de uma posição  $\zeta_i^l$  rumo a  $\zeta_i^{l+1}$ , é necessário que haja o conhecimento prévio de três variáveis: a *melhor posição* experimentada por ela em determinada iteração ( $\zeta_{PBest,i}$ ), a *melhor posição global*, isto é, experimentada por algum indivíduo no enxame ( $\zeta_{GBest}$ ) e a *velocidade* atual da partícula ( $\sigma_i^l$ ). Surge uma indagação natural neste momento: como são definidos os critérios de melhor posição individual e global? O que na natureza corresponderia à adaptabilidade a regiões com fatores ambientais prósperos, traduz-se matematicamente pelas prerrogativas de otimização de uma função objetivo ( $f_{Obj}$ ).

**Figura 5** – Uma perspectiva gráfica do PSO. Partículas (pássaros) posicionadas geograficamente na  $l$ -ésima iteração.



Fonte: o autor.

Toma-se por exemplo a Fig. 5. Nesta, o enxame é livre para migrar por todo plano

$\zeta^x \times \zeta^y \in \mathbb{R}^2$  definido tal que  $\zeta^x$  e  $\zeta^y \geq 0$ . Do conjunto de partículas, destacam-se os indivíduos  $i$  e  $j$ . Estes, após uma rotina de iterações, localizam-se em pontos oriundos de regra matemática que logo será introduzida. No entanto, ressalta-se que, até o momento de convergência às posições atuais, alguns pontos foram visitados, dentre os quais, um se sobressai ( $\zeta_{PBest,i}$ ). Foi neste ponto que, por exemplo, a partícula julgou individualmente haver abundância de recursos para sua sobrevivência. Portanto, todas as posições conhecidas pela partícula  $i$  (anteriormente), formam um conjunto  $\mathbf{p}_{prev,i} = \{\zeta_i^0, \dots, \zeta_i^l\}$  que permite a avaliação do conceito de melhor posição visitada por esta através da seguinte formulação:

$$\begin{aligned} & \underset{m}{\text{maximizar}} && f_{Obj}(\zeta_i^m) \\ & \text{submetido a} && \zeta_i^m \in \mathbf{p}_{prev,i}. \end{aligned} \quad (3.1)$$

Nesta formulação, a partícula usa o critério de maximização de recursos de sua localização geográfica  $\zeta_i^m$  através da função objetivo ( $f_{Obj}$ ). A cada iteração esta avaliação é feita pela partícula e, se houver atualização no valor de  $m$ ,  $\zeta_i^m$  é registrado em  $\zeta_{PBest,i}$ . O mesmo raciocínio segue para a avaliação do melhor global, contudo, o espaço de busca de soluções é ampliado para todas as partículas do enxame. Assim, seja  $\mathbf{g}_{prev} = \{\zeta_{PBest,1}, \dots, \zeta_{PBest,N}\}$ , a formulação para o máximo global é dada por:

$$\begin{aligned} & \underset{n}{\text{maximizar}} && f_{Obj}(\zeta_{PBest,n}) \\ & \text{submetido a} && \zeta_{PBest,n} \in \mathbf{g}_{prev}. \end{aligned} \quad (3.2)$$

Similarmente, a cada iteração esta investigação é realizada no conjunto de partículas  $e$ , se houver atualização no valor de  $n$ ,  $\zeta_{PBest,n}$  é registrado em  $\zeta_{GBest}$ .

Das três variáveis necessárias para determinação do vetor de deslocamento da partícula, apenas foram introduzidas duas:  $\zeta_{PBest,i}$  e  $\zeta_{GBest}$ , faltando assim, comentários sobre a velocidade desta. O cálculo da velocidade ( $\sigma_i^{l+1}$ ) que levará a partícula  $i$  da posição  $\zeta_i^l$  até  $\zeta_i^{l+1}$ , expressa-se analiticamente por:

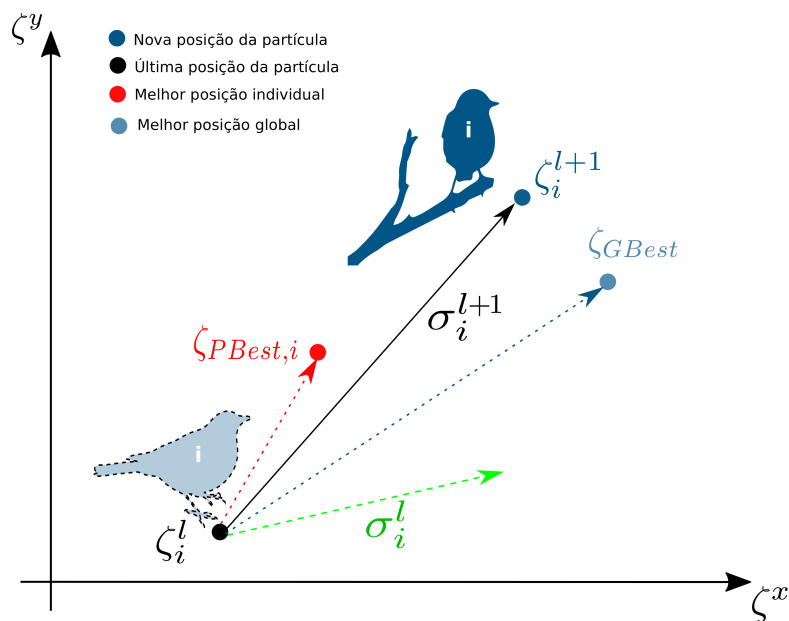
$$\sigma_i^{l+1} = k_1 u_1 (\zeta_{PBest,i} - \zeta_i^l) + k_2 u_2 (\zeta_{GBest} - \zeta_i^l) + k_3 \sigma_i^l. \quad (3.3)$$

- $k_1$  : escalar cognitivo
- $k_2$  : escalar social
- $k_3$  : coeficiente de inércia
- $u_1$  e  $u_2$  : variáveis aleatórias independentes e uniformemente distribuídas entre zero e um.

A escolha dos escalares  $k_1$  e  $k_2$  é feita de tal forma que dê celeridade ao processo de convergência. Assim, escolher valores muito baixos ( $\ll 1$ ) acarreta em convergência lenta, por outro lado, valores altos ( $\gg 1$ ) comprometem a precisão do método. A literatura recomenda (KENNEDY; EBERHART, 1995) que um valor aproximadamente igual a 2, para  $k_1$  e  $k_2$ , seja

utilizado. Alguns estudos (DONG; CHEN; SUN, 2013) também versam sobre possíveis otimizações ao escolher um valor de  $k_1$  diferente de  $k_2$ , de modo que, por exemplo, para indivíduos com altos valores de função objetivo, o coeficiente  $k_1$  é aumentado adaptativamente, enquanto que  $k_2$  é diminuído. Isto funciona como um mecanismo para dar ênfase à influência individual ou global. Este trabalho segue o raciocínio implementado por (KENNEDY; EBERHART, 1995), em que  $k_1 = k_2 = 2$ . Quanto ao coeficiente de inércia, Kennedy e Eberhart não fazem menção e o assumem igual a 1. No entanto, há variantes deste trabalho que sugerem valores diferentes (V.JADOUN et al., 2014). Uma análise mais detalhada é endereçada brevemente em A sobre o uso destes coeficientes no enredo a que este trabalho se destina.

**Figura 6** – Deslocamento de um determinado ponto  $\zeta_i^l$  para  $\zeta_i^{l+1}$  e demais variável envolvidas.



Fonte: o autor.

Com a posse destas variáveis, é possível ter em mãos a posição assumida pela partícula ao fim da iteração de ordem  $l$ . Assim, o valor assumido por esta corresponde à soma vetorial (Fig. 6) da sua posição atual (no início da iteração) com o novo valor de velocidade calculado em Eq. 3.3. Assim, segue para a partícula  $i$ :

$$\zeta_i^{l+1} = \zeta_i^l + \sigma_i^{l+1}. \quad (3.4)$$

Vale salientar que o processo é realizado iterativamente para todas as partículas do enxame. Ao fim do número preestabelecido de iterações ou até alcançar um critério satisfatório de parada, a meta-heurística encerrará o mecanismo de buscas. Para resumir, Algoritmo 1 sumariza a lógica recém-explanada.



---

**Algoritmo 1: OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS**


---

```

1  $\zeta =$  Inicialização_das_Partículas()
2 para  $l \leq$  Número_de_Iterações fazer
3   para cada  $\zeta_i \in \zeta$  fazer
4      $f_{\zeta_i^l} = f_{Obj}(\zeta_i^l)$ 
5     se  $f_{\zeta_i^l}$  é melhor do que  $f_{Obj}(\zeta_{PBest,i})$  então
6        $\zeta_{PBest,i} = \zeta_i^l$ 
7     fim
8   fim
9    $\zeta_{GBest}$  é o que tem melhor  $f_{\zeta_i^l}$  em  $\zeta$ 
10  para cada  $\zeta_i \in \zeta$  fazer
11     $\sigma_i^{l+1} = k_1 u_1 (\zeta_{PBest,i} - \zeta_i^l) + k_2 u_2 (\zeta_{GBest} - \zeta_i^l) + k_3 \sigma_i^l$ 
12     $\zeta_i^{l+1} = \zeta_i^l + \sigma_i^{l+1}$ 
13  fim
14 fim

```

---

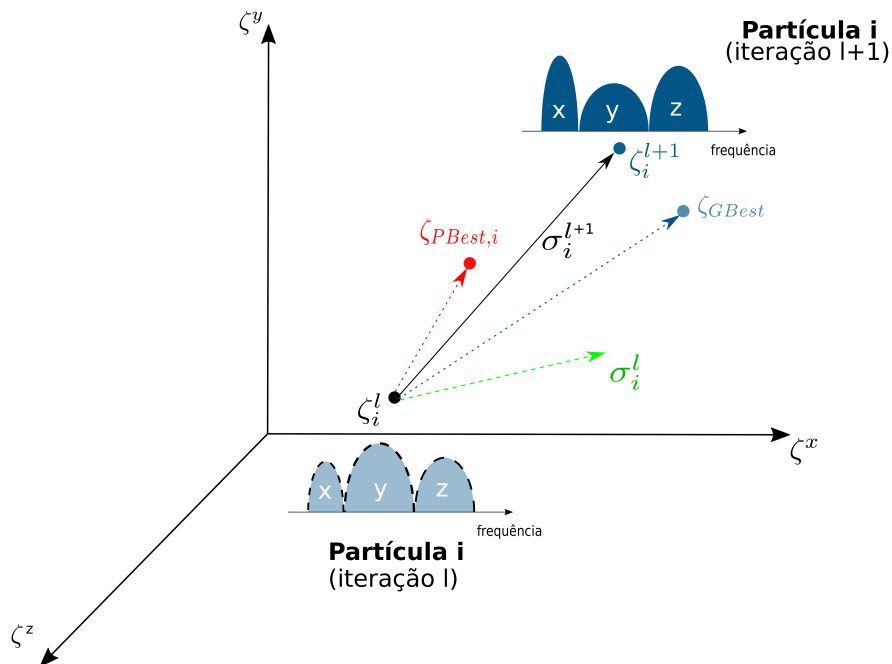
### 3.2 Adaptação para um cenário de transmissão

Tendo em vista o breve resumo da técnica apresentada, faz-se agora uma analogia com aplicação que atende um dos objetivos deste trabalho: o problema de determinação de perfis de potência que minimizam efeitos não-lineares em canais ópticos.

A explanação do método deixa claro que o uso de um espaço vetorial  $U \in \mathbb{R}^n$  permite a exploração de um conjunto de soluções em que cada uma delas é munida de um vetor de  $n$  variáveis. Assim sendo, supõe-se aqui um cenário inicial (apenas para comparação) em que uma tríade de canais ópticos conjugados é submetida à transmissão em um fluxo ponto-a-ponto em fibra SMF formado por uma quantidade de seções ópticas como as apresentadas no Capítulo 2. Sob estas condições, há o interesse em maximizar a OSNR do canal mais penalizado através de manipulação dos níveis de potência como meio de garantir QoT. Não é difícil perceber a similitude entre o enredo apresentado no Apêndice deste trabalho e este que se decorre aqui. Enquanto no primeiro as partículas estão livres para migrar em todo  $\mathbb{R}^2$ , neste, por se tratar de uma tríade de canais, claramente os fluxos de indivíduos ocorrem no  $\mathbb{R}^3$ , além disso, o que antes representava posição geográfica, agora tem significado físico de potência ( $\zeta_i^l = \{\zeta_i^{x,l}, \zeta_i^{y,l}, \zeta_i^{z,l}\}$ , em W).

Como a Fig. 7 expõe, cada um dos três canais x,y e z da partícula  $i$  (na  $l$ -ésima iteração), possui um nível de potência:  $\zeta_i^{x,l}, \zeta_i^{y,l}, \zeta_i^{z,l}$ , que pertence ao domínio:  $\zeta^x, \zeta^y$  e  $\zeta^z \in \mathbb{R}$ , respectivamente. Cada valor de potência está submetido às regras de evolução descritas no Algoritmo 1. Esta, portanto, é a estrutura de indivíduo que será utilizada nas otimizações abordadas neste capítulo. A simples diferença está número de canais utilizados, já que uma tríade de portadoras é um caso de pouco interesse de estudo prático. Por fim, o uso da técnica de otimização por enxame de partículas neste contexto foi visto como uma oportunidade para explorar as virtudes

**Figura 7** – Um analogia introdutória para tríade de canais ópticos conjugados.



Fonte: o autor.

(simplicidade, análise numérica, etc.) deste recurso matemático em um campo onde predomina, na literatura, a utilização de métodos matemáticos tradicionais.

### 3.3 Uma alternativa para técnicas de otimização tradicionais

O desenvolvimento até aqui discutido seria de débil utilização se não comprovado em contextos de transmissão óptica em que técnicas de otimização tradicionais têm sido largamente implementadas. Logo, como etapa de validação do raciocínio decorrido, retrata-se nas próximas linhas um contraste da técnica evolucionária de otimização com método de programação matemática apresentado em (IVES; SAVORY, 2013) considerando-se condições idênticas de propagação.

Muito se discute sobre a eficácia de perfis de lançamento de potência em redes ópticas na mitigação de efeitos não-lineares. Ao contrário da cômoda e rotineira abordagem encontrada em cenários de redes com todos os canais lançados com mesma potência, o conhecimento de modelos de propagação não-linear capacita a investigação de que tal procedimento está longe do ótimo.

Encontram-se na literatura inúmeras tentativas de parametrizar modelos analíticos de perfis de potência para canais WDM. Em (PAVEL, 2006), por exemplo, conclui-se que o uso de curvas parabólicas como artifício de atenuação de efeitos não-lineares é satisfatório, o qual é posteriormente verificado em (IVES; BAYVEL; SAVORY, 2014). Em outro estudo, levantado por

(NAKASHIMA et al., 2015), a questão da alocação/arranjo espectral é levada em consideração juntamente com a otimização de potência. No entanto, estas abordagens retringem-se a um cenário exclusivo e de pouco interesse. Quando contextos mais sofisticados em termos de tráfego (inclusão de nós ADD/DROP, não negligenciamento de limiar de OSNR, etc.) são considerados, percebe-se que a escolha de curvas contínuas (e.g., parabólicas) é apenas uma possível solução em um contexto heterogêneo. Para efeito de comparação, os modelos aqui apresentados são contrapostos com as tratativas assumidas em (IVES; SAVORY, 2013). Nesta publicação, desenha-se uma rede onde seis canais destinam-se a atender demandas de fluxo por três percursos (vide Fig. 8):  $A$  (12 spans),  $B$  (6 spans) e  $B^+$  (6 spans). No percurso  $A$ , seis canais (para facilitar a referência, denominados canais  $A$ ) têm a incumbência de trafegar pelos nós 1, 2 e 3. Pelos outros dois caminhos, ou seja,  $B$  e  $B^+$ , 6 canais completam a metade do trajeto, entre nó 1 e 2 (canais  $B$ ) e os demais 6 (canais  $B^+$ ) substituem os canais  $B$  no itinerário do nó 2 ao 3. Todas as requisições possuem taxa de bits de 100 Gbps, nível de modulação PM-4QAM (caracterizando um contexto ainda WDM) e banda de guarda de 25 GHz.

Por fim, os resultados numéricos aqui comparados com (IVES; SAVORY, 2013) utilizaram-se dos dois modelos de propagação não-linear publicados em (POGGIOLINI et al., 2014) e (JOHANNISSON; AGRELL, 2014) já introduzidos no Capítulo 2, usando o PSO como técnica de otimização matemática. Para facilitar a nomenclatura, referenciam-se estes dois modelos por Proposto 1 e Proposto 2, respectivamente. Por outro lado, uma formulação MILP é utilizada em (IVES; SAVORY, 2013) baseando-se em um modelo de propagação não-linear mais antigo descrito em (CARENA et al., 2012). Uma observação é feita, no entanto. Para o cálculo de OSNR dos modelos aqui seguidos, despreza-se a influência da SCI, pois esta pode ser totalmente mitigada pelo projeto apropriado do receptor (IRUKULAPATI et al., 2014). Resumindo, as análises aqui comparadas, são: formulação MILP com modelo não-linear encontrado em (CARENA et al., 2012) (**Ives et. al., 2013**), otimização por enxame de partículas e modelo não-linear de (POGGIOLINI et al., 2014) (**Proposto 1**) e otimização por enxame de partículas e modelo não-linear de (JOHANNISSON; AGRELL, 2014) (**Proposto 2**).


As análises sugerem três tipos de regime para otimização de potência:

- Todos os canais da rede com potência constante;
- Canais com demandas de tráfego idênticas possuem mesma potência;
- Canais com potências otimizadas individualmente.

### 3.3.1 Modelo de canais com potência constante

Nesta primeira etapa, é analisada a maximização de OSNR do canal mais penalizado devido às imperfeições não-lineares. A otimização, neste caso, não é feita com relação à margem de OSNR, pois todos os canais possuem mesmo nível de modulação, o que impacta da mesma forma. É feita a ressalva, porém, de que todas as demandas devem possuir o mesmo nível de potência. Os canais  $A$ , anteriormente referenciados, assumem as 6 primeiras posições do espectro

**Figura 8** – Rede WDM para comparação de modelos físicos e técnicas matemáticas de otimização.



Fonte: o autor.

( $1 \leq i \leq 6$ ), enquanto os canais  $B$  e  $B^+$  ( $6 < i \leq 12$ ) revezam as 6 últimas. Isto resume-se, em:

$$\begin{aligned} & \underset{s}{\text{maximizar}} \quad \min[OSNR(s)] \\ & \text{submetido a} \quad Pot_i(s) = P, \forall i \leq 12. \end{aligned} \quad (3.5)$$

A variável  $s$  significa o conjunto formado pelos 12 canais ópticos e  $Pot_i(s)$  expressa o valor de potência do canal de ordem  $i$ , que neste caso é constante e igual a  $P$  para qualquer  $i$ .

Os parâmetros considerados no *design* da rede deste e dos outros dois regimes são os da Tabela 1. De forma complementar, considerou-se também que o ganho dos amplificadores compensa totalmente a perda na fibra e a soma dos ruídos (ASE e não-linear) é feita de forma incoerente. Por fim, na otimização com PSO, 50 indivíduos foram utilizados com um número de 100 iterações. Os parâmetros aqui empregados foram os mesmos do exemplo do Apêndice ( $k_1 = k_2 = 2$  e  $k_3 = 0, 5$ ).


**Tabela 1** – Parâmetros Físicos da Rede

Numero de Spans	12
Comprimento do Span	100 km
Coefficiente de dispersão cromática	$16,7 \text{ ps.nm}^{-1}.\text{km}^{-1}$
Coefficiente não-linear	$1,31 \text{ W}^{-1}.\text{km}^{-1}$
Coefficiente de atenuação	$0,22 \text{ dB.km}^{-1}$
Figura de Ruído do Amplificador	5 dB

A análise gráfica da Fig. 9 permite observar não somente a concordância tanto em termos de comportamento de curva como em proximidade dos resultados quando comparam-se os métodos propostos 1 e 2 com o publicado. É válido ressaltar, também, que a junção da técnica evolucionária com os modelos físicos aplicados garantem velocidade em convergência, dado que resultados satisfatórios foram obtidos com apenas 100 iterações.

Como é possível perceber, para otimização com todos canais com mesmo valor de potência, obtém-se uma OSNR mínima em torno de 16,2 dB para o proposto 1, o qual será

**Figura 9** – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando todos canais possuem mesma potência.



Fonte: o autor.

tomado como modelo mais apropriado para comparação, tendo em vista que o proposto 2 já é uma simplificação do 1. A ideia dos próximos dois regimes é mostrar que há ganhos em não trabalhar com todos canais com mesma potência.

Um segundo ponto a validar é o comportamento das curvas de OSNR para este regime. Pelo observado, esta configuração penaliza fortemente os canais centrais, devido à exposição bilateral da vizinhança. Também, é possível identificar que as demandas  $B/B^+$  conseguem ter nível de OSNR mais elevado, quando a comparação é feita com as demandas do tipo  $A$ . Isto se dá por causa da menor distância de propagação (6 spans) e, conseqüentemente, devido ao menor tempo de exposição à influência não-linear.

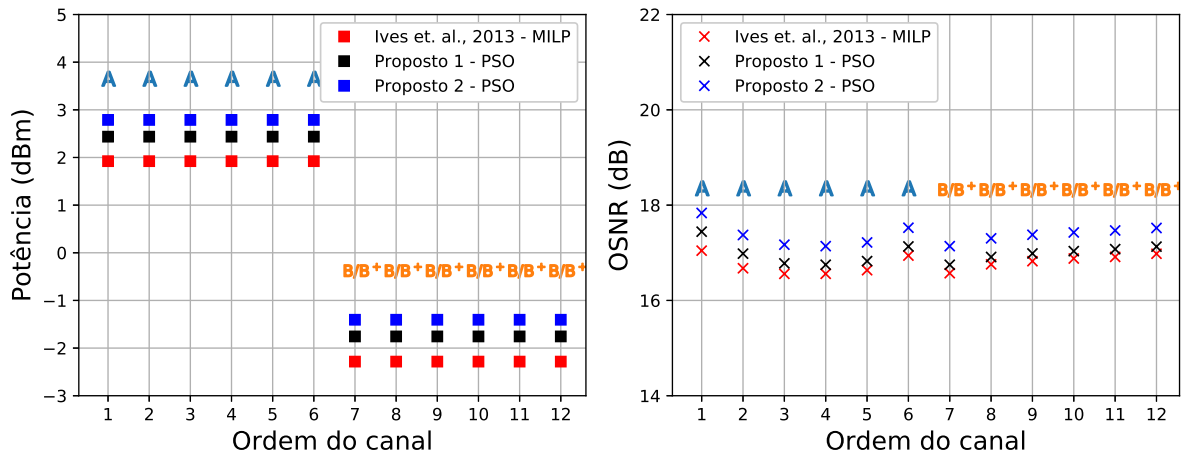
### 3.3.2 Modelo de canais com potência agrupada

Neste segundo momento, investiga-se o impacto de permitir que canais com demandas semelhantes de tráfego possuam potências iguais, por exemplo, os canais  $A$  têm um percurso de 12 seções e teriam um nível de potência igual a  $P_1$ , por outro lado, os canais  $B$  e  $B^+$  trafegam por 6 seções apenas, logo, possuiriam potência  $P_2$ . Neste caso, novamente utiliza-se o critério de alocação usado em 3.1, isto é, para  $1 \leq i \leq 6 \rightarrow$  canais  $A$ , se  $6 < i \leq 12 \rightarrow$  canais  $B/B^+$ . Desta forma, a sentença de otimização será escrita como:

$$\begin{aligned} & \underset{s}{\text{maximizar}} \quad \min[OSNR(s)] \\ & \text{submetido a} \quad Pot_i(s) = \begin{cases} P_1, & \text{se } i \leq 6 \\ P_2, & \text{caso contrário} \end{cases} \end{aligned} \quad (3.6)$$

Neste novo regime, é possível averiguar que a simples distinção entre potências quando a

**Figura 10** – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando o regime de potência agrupada é investigado.



Fonte: o autor.

demanda de tráfego é levada em consideração permite que a OSNR do canal mais penalizado seja de 16,7 dB. Este ganho, em comparação ao regime anterior, demonstra que é válida a prerrogativa de que caminhos mais curtos demandam potências mais baixas (vide Fig. 10).

Um ponto interessante a se destacar nesta análise é o fato de que a simples distinção de potências permite que agora os canais centrais não sejam os mais penalizados (quando o foco é as demandas do tipo A). Isto ocorre pois como a potência dos canais  $B/B^+$  é menor, estes perdem significância em termos de influência não-linear sobre as demandas A. Se a atenção for voltada para as demandas  $B/B^+$ , observa-se, por outro lado, que os canais A impõem uma influência significativa já que o decréscimo em termos de OSNR (dos canais  $B/B^+$ ) no centro do espectro é elevado.

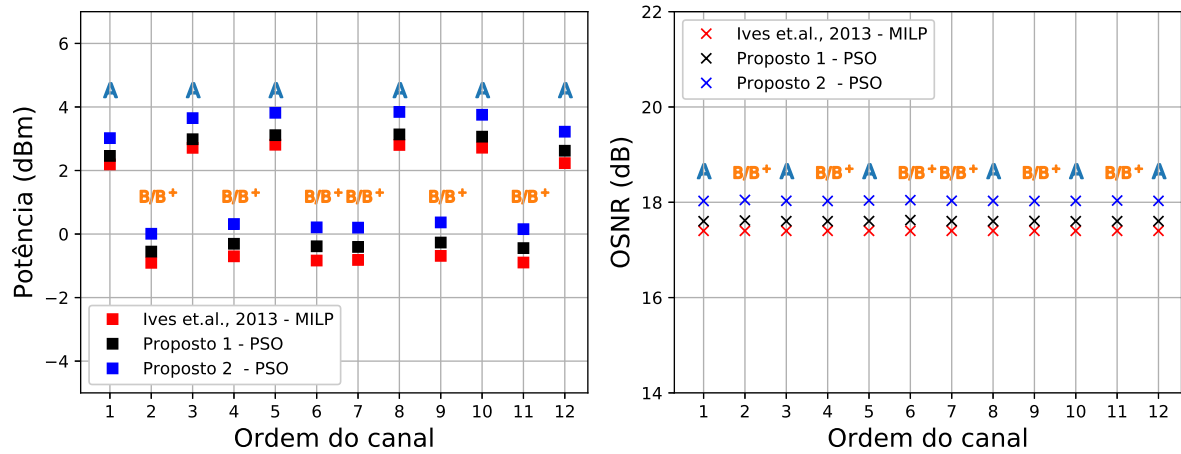
### 3.3.3 Modelo de canais com potência otimizada individualmente

Por fim, considera-se a proposta de individualização dos níveis de potência de cada canal. Neste caso, não é negligenciada a alocação espectral. Para tal, realiza-se uma busca exaustiva em todos os 924 possíveis arranjos com os canais A e  $B/B^+$ , seguida de otimização de potência. Com a análise de todas as possibilidades, percebeu-se que o perfil onde há um comportamento de alternância de canais (A,  $B/B^+$ , A,  $B/B^+$ ...) é o que garante maior nível de OSNR mínima. Portanto, reformulando o problema de otimização de potência, tem-se:

$$\begin{aligned} & \underset{s}{\text{maximizar}} && \min[OSNR(s)] \\ & \text{submetido a} && Pot_i(s) = P_i, \forall i \leq 12. \end{aligned} \quad (3.7)$$

A Fig. 11 confirma que a a reorganização espectral seguida de otimização de potência garante um ganho de aproximadamente 1,4 dB quando comparada ao primeiro regime. Esta

**Figura 11** – Comparação de métodos Propostos (1 e 2) com resultado publicado em (IVES; SAVORY, 2013) quando o regime de potência otimizada individualmente aliada à reorganização espectral ótima é investigada.



Fonte: o autor.

análise dá ignição ao interesse de se investigar, de forma mais eficiente, métodos que garantam a análise de rearranjo espectral ao mesmo tempo que o problema de achar perfis ótimos de potência não seja menosprezado. Outro problema até agora pouco discutido é a questão de economia de banda, visto que em todos cenários considerou-se o uso de canais WDM. Adiantando, estes questionamentos serão devidamente endereçados no Capítulo 4 através da formulação de um método evolucionário que supre as demandas aqui deixadas.

Mais uma vez, é possível identificar que o PSO tem proximidade satisfatória quando comparado aos resultados obtidos com métodos de programação matemática. Além disso, a quantidade de iterações e o tempo total de processamento (inferior a 30s), o elegem como um propício estimador em cenários de busca por perfis de potência.

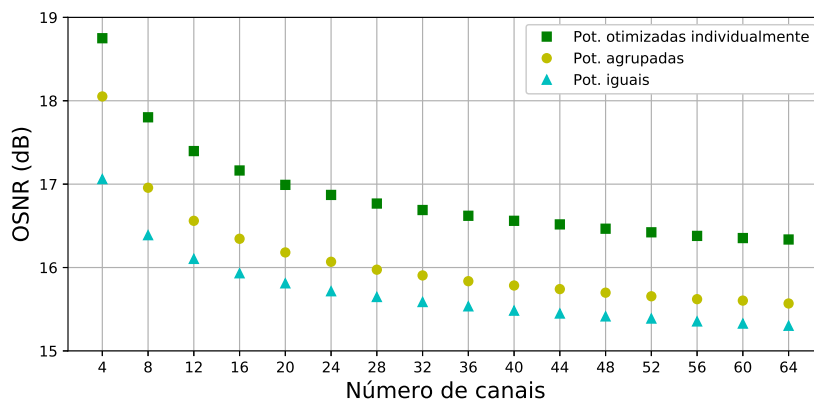
Por fim, uma característica importante a se levantar é o fato de a busca por uma otimização individual (em termos de arranjo espectral e potência) permitir uma equalização da curva de OSNR, algo desejável sob o ponto de vista de *fairness* da rede.

### 3.4 Uma análise adicional

Nas exposições realizadas até o momento, percebe-se que a otimização de potências individualizadas acompanhada da busca pelo melhor arranjo espectral permite que um ganho de OSNR do canal mais penalizado seja alcançado. Dúvidas poderiam emergir quanto à validade desta afirmação quando dá-se o crescimento do número de canais. Para responder este questionamento, expandem-se as três análises para cenários de maior ocupação do espectro. O resultado pode ser inspecionado na Fig. 12. Nesta, é visível que o regime discuido em (3.4.3), para qualquer estado de ocupação, possui OSNR mínima mais elevada em comparação às outras

duas tratativas.

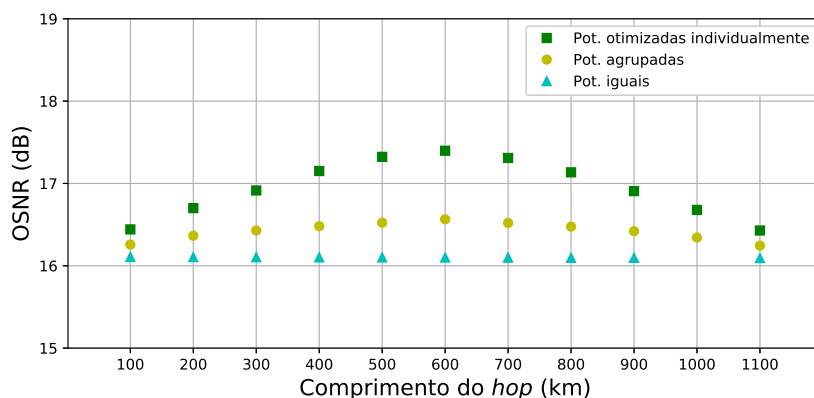
**Figura 12** – Comportamento dos três regimes quando a ocupação da rede é levada em consideração



Fonte: o autor.

Poderia ser questionado também se o comprimento dos *hops* influenciaria nesta análise. Novamente, prova-se que para a topologia de estudo, alterar o comprimento do primeiro *hop*, deixando-se o tamanho da rede fixo, não compromete o fato de que canais otimizados individualmente são o melhor regime, avaliando-se a OSNR mínima (Fig. 13).

**Figura 13** – Comportamento dos três regimes quando o comprimento do primeiro *hop* da rede é levado em consideração



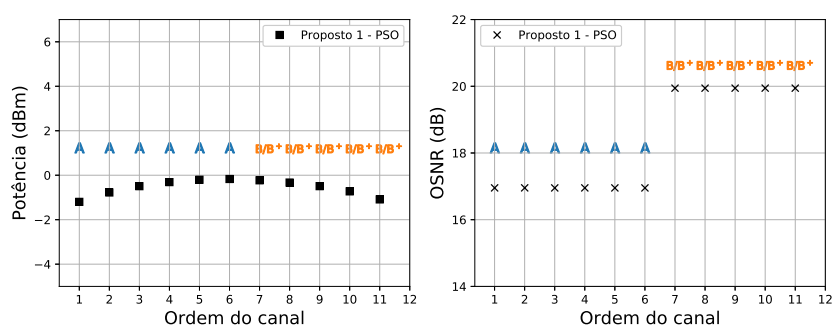
Fonte: o autor.

Como é possível perceber, a técnica de otimização por enxame de partículas mostra-se uma solução aplicável a cenários de transmissão em redes ópticas na determinação de perfis de potência com aproximação satisfatória quando comparada a formulações MILPs. Todavia, o raciocínio aqui percorrido somente abrange metade dos problemas propostos até o momento, pois a otimização de arranjos espectrais ainda não foi totalmente satisfeita. Em (IVES; SAVORY, 2013) a proposta de busca exaustiva combinatorial torna-se totalmente inapropriada quando a heterogeneidade de canais é demandada. Nos casos propostos anteriormente, considerou-se apenas o simples desenho de doze canais ópticos, que por natureza do problema já possuíam



modulação e taxa de bits definidas. Contudo, em tratativas reais, o uso de modulações variadas garante aumento de capacidade, que foi negligenciado como critério de otimização. Uma prova desta afirmação pode ser investigada na Fig. 14. Nesta, não mais otimiza-se a OSNR, mas sim margem de OSNR, operando-se com canais  $A$ , a 200 Gbps em PM-16QAM, e  $B/B^+$ , com 250 Gbps em PM-32QAM. O limiar de OSNR dos canais  $A$  é de 15,2 dB, enquanto que para os  $B/B^+$  é de 18,2 dB. A otimização mostra que permitir modulações com nível mais alto garante aumentar a taxa de dados com mesma banda sem comprometer QoT. Esta capacidade de olhar para o espectro como possível fonte de otimização, como já mencionado, será abordada no próximo capítulo.

**Figura 14** – Exemplo de como aumentar a taxa total transmitida sem comprometer QoT.



Fonte: o autor.

O PSO, como ressaltado anteriormente, limita o problema à determinação de variáveis contínuas. Qualquer tentativa de discretização durante o processo acarreta em fuga dos princípios que norteiam o método. Isto atrapalharia na investida de empregar o algoritmo na busca de arranjos espectrais mais robustos à não-linearidade. Como solução imediata, pensa-se em métodos de otimização que permitam discretização das variáveis e a consequente adequação aos critérios aqui exigidos. Para suprir estas demandas, surge a ideia de tratar este problema de transmissão óptica com recursos encontrados no algoritmo genético, que serão discutidos nas próximas linhas.

## 4 ALGORITMO GENÉTICO COMO SOLUCIONADOR DE OTIMIZAÇÃO DISCRETA EM CANAIS ÓPTICOS ELÁSTICOS

No capítulo anterior, discutiu-se a capacidade da técnica de otimização evolucionária por enxame de partículas em determinar perfis de potência que suavizem as imperfeições não-lineares encontradas na camada física. Igualmente importante ao fato de perceber que a técnica tem satisfatória resposta ao contexto proposto no que se refere à velocidade de convergência e proximidade dos resultados é concluir que existe ganho em QoT e em capacidade de transmissão quando a otimização conjunta de potência e banda é levada em conta. Tendo em vista as restrições do PSO num tratamento pleno das variáveis que compõem o enredo de transmissão óptica, surge, sob a perspectiva de uma segunda técnica evolucionária, a esperança em suprir as demandas de heterogeneidade de canais encontrada em redes elásticas.

### 4.1 Conhecendo um pouco da história da meta-heurística

Estudos relacionados à elaboração do algoritmo genético remontam da década de 50. Mais precisamente, em 1953, quando o cientista Nils Barricelli foi convidado para a universidade de Princeton com o intuito de usar um dos primeiros computadores digitais para escrever softwares que reproduzissem comportamentos naturais de reprodução e mutação. Apesar de seu intuito principal não ser a otimização de funções ou até mesmo simular evoluções biológicas, ele criou o que ficou conhecido como primeiro software de algoritmo genético (SIMON, 2013). Quatro anos após, seu trabalho foi seguido por Alexander Fraser, biólogo londrino que teve a ideia de usar recursos computacionais de programação para estudar evolução. No entanto, foi em 1960 que John Holland (MITCHEL, 1996) oficialmente inventou, ou pelo menos uma versão inicial, o que hoje é conhecido como algoritmo genético. A versão de Holland envolvia aspectos da teoria *Darwiniana* conhecida como “*survival of the fittest*” (que traduz-se por sobrevivência do mais apto), bem como processos de cruzamento, recombinação e mutação, similamente ao encontrado na genética. Seus estudos foram movidos pela curiosidade em compreender como sistemas se adaptam às circunstâncias que os cercam. Foi em 1975, porém, que Holland consolidou anos de estudos e contribuições de alunos através do livro “*Adaptation in Natural and Artificial Systems*”. Neste, Holland apresenta o algoritmo genético como uma “abstração da evolução da Biologia” e concede um contexto teórico para a tratativa. Este livro permaneceu até recentemente como uma base de fundamentos para algoritmos genéticos e boa parte de trabalhos que discutiam o tema se referenciavam a este.

O “*boom*” em pesquisas sobre algoritmos genéticos deu-se entre 1970 e 1980, particularmente devido a avanços em tecnologia. Além disso, cientistas começaram a perceber a limitação de técnicas convencionais de otimização para resolver problemas complexos. A vantagem do algoritmo genético (que será referenciado de agora em diante por GA), assim como

o PSO, é que conseguem simultaneamente testar múltiplos pontos de todo espaço de soluções, trabalhar com vários tipos de dados e, mais importante, gerar diferentes tipos de resultados que podem ser investigadas sob a ótica de relações de compromisso (HAUPT, 1998). Estes benefícios permitem “*produzir resultados impressionantes enquanto técnicas tradicionais falham miseravelmente.*”(HAUPT, 1998).

Por *métodos tradicionais* referenciam-se, como visto no Capítulo 3, os três principais tipos: baseado em Cálculo Diferencial, busca exaustiva e busca aleatória. As técnicas baseadas em Cálculo subdividem-se em duas categorias: direta e indireta. Na direta, segue-se a direção da função gradiente em busca de mínimos/máximos globais. Na indireta, iguala-se o gradiente da função a zero e resolve-se a equação diferencial resultante. Apesar da robustez e sofisticação que estas técnicas ganharam com os anos, deixam a desejar em certos pontos. O primeiro é o fato de que somente procuram ótimos locais, o que as faz ineficientes quando nada se sabe sobre a vizinhança de ótimos globais. Por último, estes métodos demandam que as funções sejam deriváveis, o que raramente se dá em casos práticos.

Busca exaustiva requer um espaço de busca finito (ou infinito e discretizado) para os possíveis valores da função objetivo. Assim, cada possível valor é testado por vez para achar o ótimo. Apesar de ser atrativo, pois inspeciona todas possíveis combinações e retorna o melhor resultado, é o menos eficiente de todos processos de otimização, principalmente em casos em que os espaços de busca são de dimensões vastas para testar cada possibilidade.

Na busca aleatória, uma sub-amostra do espaço de buscas é tomada e determina-se o ótimo dentro do conjunto. Apesar de ser rápido, este método é estatisticamente esperado não ter rendimento melhor do que a busca exaustiva. Outro ponto a se levantar é o fato de que não há indicações do quão próximo ou distante a solução está do ótimo global.

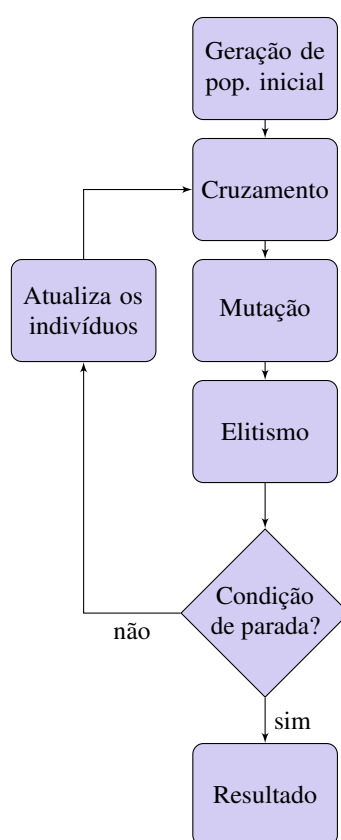
Enquanto isso, GA tem grande vantagem em cima destes métodos tradicionais. No GA há a progressão de uma população de candidatos pulverizados (dispersos) no espaço de buscas, enquanto no baseado em Cálculo Diferencial reduz-se a um único ponto. Isto reduz enormemente a probabilidade de encontrar um ótimo local ao invés de global. Além disso, e igualmente importante, é o fato de o GA não requerer informação extra (e.g., derivadas). O único mecanismo que guia a procura é a avaliação numérica da função objetivo. Isto permite a avaliação em ambientes ruidosos, não deriváveis e, principalmente, não lineares. Além disso, o GA pode ser ajustável, ou seja, dá liberdade para escolha dos tipos de soluções de acordo com as demandas de acurácia ou eficiência.

Após esta breve abordagem histórica, a próxima seção destina-se a criar um ambiente que explora os conceitos técnicos do GA sempre montando a analogia com o cenário de transmissão óptica que motivou a elaboração deste trabalho. Isto permitirá, mais adiante, a análise das demandas não supridas no Capítulo 3. Com o intuito de não quebrar a familiaridade do leitor com a nomenclatura até então construída, alguns símbolos do Capítulo 3 serão reutilizados .

## 4.2 Detalhando a técnica

O entendimento completo do GA passa pela compreensão das quatro etapas básicas que o compõem: Geração de população inicial, Cruzamento, Mutação e Elitismo. Os indivíduos, inseridos através da etapa única de Geração de população inicial, são iterativamente avaliados pelos critérios do processo de Elitismo, que determinam quais características o fazem sobreviver ou padecer às condições impostas pelo ambiente. Os motores de evolução estão diretamente ligados às etapas de Mutação e Cruzamento. Uma visão macro e introdutória da técnica é apresentada no fluxo da Fig. 15.

**Figura 15** – Diagrama de fluxo básico para entendimento do GA.



Fonte: o autor.

### 4.2.1 Geração de população inicial

No GA, a inicialização da população é realizada no começo do mecanismo. Portanto, tomando emprestados os símbolos (e alguns termos) do capítulo anterior, dada uma população com  $N$  indivíduos, em que cada um possui uma identificação  $i$ , em que  $1 \leq i \leq N$ , por  $\zeta_i^l$  lê-se a característica assumida pela partícula  $i$  ao início da  $l$ -ésima iteração. É importante ressaltar um detalhe. Enquanto no Capítulo 3 interpretava-se a variável  $\zeta$  por uma posição geográfica (a exemplo de pássaros em um ecossistema), agora, esta pode ser entendida como um conjunto de características discretas (genes) que formam um indivíduo (cromossomo). Talvez ainda

esteja nebuloso o conceito, mas o leitor ficará mais confortável com o entendimento durante o decorrer deste capítulo. Por ora, é necessário assimilar que o início do mecanismo exige que as características de cada indivíduo sejam concedidas de forma aleatória e tal que pulverize o espaço de buscas com diversidade. A primeira dúvida pode surgir em relação ao que isto se assemelha a canais ópticos elásticos sendo transmitidos em um fluxo ponto-a-ponto. A resposta desenha-se através das analogias descritas a seguir.


Assim como um cromossomo é formado por uma quantidade de genes, ou seja, unidades fundamentais de hereditariedade que determinam características de um indivíduo, o espectro óptico é formado por canais elásticos, ou pela ausência deles durante certos intervalos, e que também determinam peculiaridade do status de transmissão em uma rede. Se uma investigação mais detalhada for feita, ao olhar para genes vê-se uma composição feita por sequências de DNA (molécula de arranjo helicoidal com instruções genéticas), o qual nada mais é que a disposição em pares de quatro nucleobases (*citocina*, *guanina*, *adenina* e *timina*). Similarmente, olhando-se sob a perspectiva da fotônica, cada canal óptico é formado pelo arranjo quádruplo composto por: uma frequência central, uma taxa de bits, formato de modulação e um nível de potência. A Fig.16 resume esta ponte entre os dois sistemas

#### 4.2.2 Cruzamento

Dada a geração de população inicial, os indivíduos são postos a interagir num processo que determina a primeira fase de reprodução, o Cruzamento. Nesta etapa, as partículas da população são pareadas e realizam uma permuta (atendendo a uma probabilidade  $Pr_C$ ) de material genético entre si, visando gerar novos indivíduos diversificados. Quais materiais genéticos que serão permutados depende apenas do *crossover-point* (ponto de cruzamento). Voltando para o exemplo no contexto deste trabalho, suponha duas possibilidades de arranjo do espectro com 6 canais ópticos, como representado na Fig. 17. A estas duas possibilidades serão dados os nomes de *Ascendente 1* ( $\zeta_{A1}$ ) e *Ascendente 2* ( $\zeta_{A2}$ ). Imaginando agora que o espectro seja seccionado em duas faixas com um número inteiro de canais para cada uma, então, se neste exemplo trabalha-se com 6 canais é mais do que nítido que existem 5 possibilidades de corte. Para ficar mais claro, as 5 possibilidades de secção inferidas são entre: canais 1 e 2, 2 e 3, 3 e 4, 4 e 5 e 5 e 6. Esta operação de corte deve dar-se para os dois indivíduos  $\zeta_{A1}$  e  $\zeta_{A2}$  na mesma posição, assumindo que a escolha ponto de cruzamento é feita de forma aleatória uniformemente distribuída entre as cinco possibilidades expostas. Com a realização do corte, as quatro faixas de material genético geradas pelos indivíduos ascendentes se unem de forma complementar com o intuito de gerar outros dois indivíduos descendentes ( $\zeta_{D1}$  e  $\zeta_{D2}$ ) e novos na população. Uma outra perspectiva da lógica permite identificar que o que houve foi nada menos do que a concatenação cruzada de canais.

A compreensão gráfica deste mecanismo é explorada na Fig. 17 através dos dos identificadores I.a e I.b.

**Figura 16** – Comparação entre cromossomo e conjunto de canais ópticos transmitidos em fibra.



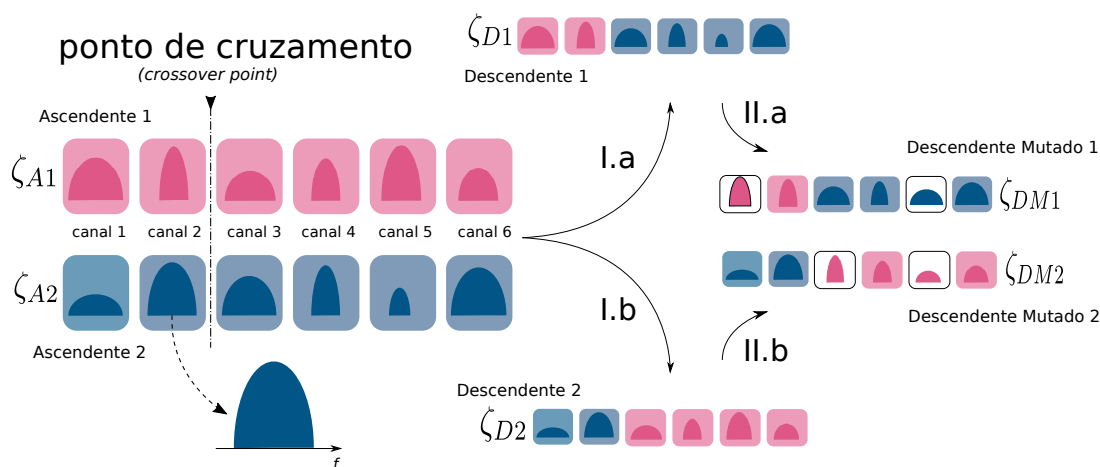
Fonte: o autor.

### 4.2.3 Mutaç o

O entendimento desta fase   mais direto do que a anterior. Este mecanismo replica a opera o de Muta o presente na gen tica, que ocorre quando h  uma mudan a na sequ ncia de genes. Esta altera o, que pode de ser de natureza d iversa (invers o dos genes, perda, inser o), implica no aparecimento de caracter sticas diferentes no indiv duo que podem trazer benef cios   sobreviv ncia deste ou n o. Mais uma vez, no contexto deste trabalho, este mecanismo ser  retratado pela altera o de caracter sticas que comp em um determinado canal  ptico. Por exemplo, suponha que os 6 canais  pticos dos indiv duos descendentes no sistema ap s a etapa de Cruzamento, isto  ,  $\zeta_{D1}$  e  $\zeta_{D2}$ , sejam analisados individualmente e se obedecerem a uma determinada probabilidade ( $Pr_M$ ), ter o caracter sticas suas modificadas aleatoriamente (modula o, pot ncia, taxa de bits). Os dois novos indiv duos gerados t m identifica es  $\zeta_{DM1}$ ,  $\zeta_{DM2}$  (Descendentes Mutados).

A estocacidade deste processo permite que diversidade seja gerada na popula o e novas condi es de sobreviv ncia sejam avaliadas. Novamente, o entendimento gr fico deste mecanismo   explorado na Fig. 17 pelos identificadores II.a e II.b.

**Figura 17** – Mecanismos de cruzamento (I.a e I.b) e Mutação (II.a e II.b) em conjunto de canais ópticos elásticos.



Fonte: o autor.

#### 4.2.4 Elitismo

Esta etapa torna-se uma das mais importantes do GA, pois é aqui que são avaliados os indivíduos que mais se adaptam às condições impostas à sobrevivência. Traçando um paralelo com a realidade deste trabalho, a seleção de candidatos elegíveis é feita através da função objetivo, seguindo o mesmo raciocínio discutido no Capítulo 3. Adiante, será visto que mais de uma função objetivo pode ser utilizada, introduzindo o conceito de multiobjetividade. Neste caso, critérios de não dominância precisarão ser levados em conta, o que é propriedade do método chamado NSGA-II.

Por fim, um breve comentário deve ser tecido sobre as condições de convergência. Nos cenários trabalhados ao longo deste capítulo considerou-se como condição de parada das iterações, a não alteração significativa da frente de Pareto, conceito este que será introduzido durante a descrição do NSGA-II.

### 4.3 NSGA-II

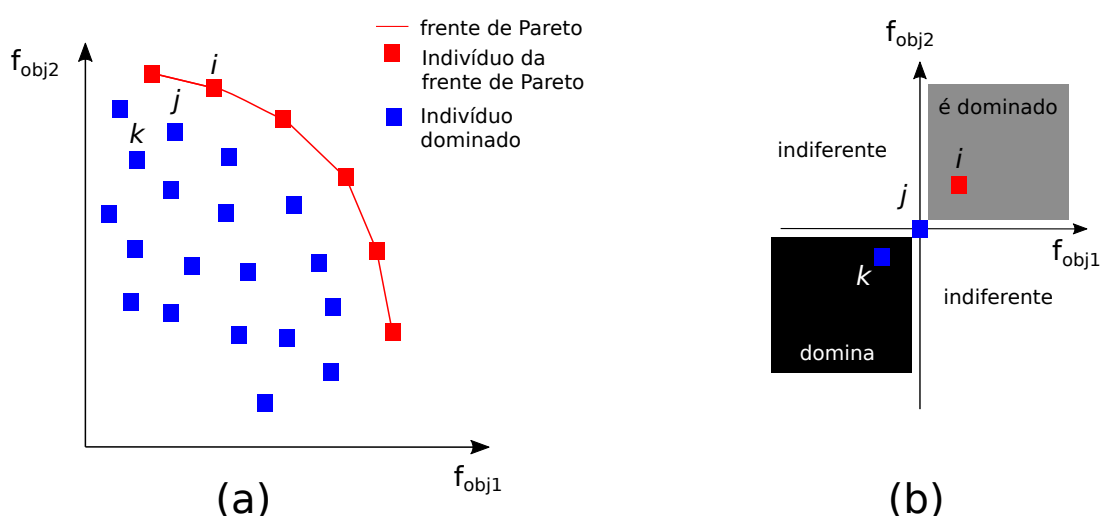
O NSGA-II (do inglês, *Non-dominated Sorting Genetic Algorithm II*) é um algoritmo genético (MITCHEL, 1996) que se baseia no conceito da não-dominância para seleção de indivíduos. Nesta tratativa, utiliza-se um princípio bem popular da Economia chamado de: Eficiência de Pareto.

Eficiência ou ótimo de Pareto é um conceito desenvolvido pelo italiano economista *Vilfredo Pareto*, em que se define um estado de distribuição de recursos no qual é impossível realocá-los tal que a situação de qualquer participante seja melhorada sem piorar a situação individual de outro participante. Neste conceito, trabalha-se com um termo denominado "*frente de Pareto*". Esta frente é o conjunto de todas as alocações eficientes, convencionalmente mostradas a partir de curvas. Veja, por exemplo, a Fig. 18. Nesta, deseja-se analisar não mais uma única

função objetivo, mas agora duas ( $f_{Obj1}$ ,  $f_{Obj2}$ ). Neste caso, busca-se otimizar os recursos através de, por exemplo, maximização das duas funções de onde é possível obter a distribuição gráfica mencionada. Logo, determina-se por frente de Pareto o conjunto de indivíduos (recursos) que não são dominados em termos de  $f_{Obj1}$  e  $f_{Obj2}$ , em toda população. Em termos matemáticos, para que um indivíduo  $i$  pertença à frente de Pareto, é preciso que não haja um indivíduo  $j$  tal que:

$$f_{Obj1}(\zeta_j) \geq f_{Obj1}(\zeta_i) \cap f_{Obj2}(\zeta_j) \geq f_{Obj2}(\zeta_i) \quad (4.1)$$

**Figura 18** – (a) Ilustração da curva de Pareto e distribuição dos indivíduos. (b) Relações de dominância em referência ao indivíduo  $j$ .



Fonte: o autor.

Para o caso de maximização das duas funções objetivos, como mostra a Fig. 18.a, é possível também investigar graficamente se o indivíduo é dominado ou não checando se há a presença de qualquer outro indivíduo no seu primeiro quadrante. Se houver, infringe a relação 4.1 e logo,  $i \notin$  frente de Pareto. Portanto, é através do critério de dominância que o algoritmo agrega o conceito de Elitismo e, assim, consegue dividir a população em diversos níveis (ou frentes), o que permite a categorização das soluções. A Fig. 18.b também reporta este critério de dominância quando o indivíduo  $j$  é levado em consideração. Por exemplo, como neste caso optou-se por maximizar as duas funções objetivos, então, o indivíduo  $j$  é dominado pelo  $i$  e domina o  $k$ .

O NSGA II também se sobressai por possuir duas sub-etapas importantes no processo de Elitismo, que são: o *Fast Non-Dominated Sorting* e o *Crowding Distance*. A presença da segunda sub-etapa, por exemplo, permite que algumas circunstâncias eventuais sejam manuseadas apropriadamente durante as seleção de indivíduos. Para ilustrar, quando o número de indivíduos na frente de Pareto, ou seja, indivíduos não-dominados, supera o tamanho da população com a qual o Algoritmo está preparado para trabalhar, o processo de *Crowding Distance* determinará quais soluções devem ser escolhidas para evitar a concentração de características.



### 4.3.1 Fast Non-Dominated Sorting

Em suma, é durante este processo que cada indivíduo  $i$  é comparado, em termos de grau de dominância ( $g_{d,i}$ ), com todos outros participantes  $j$  dentro da população. Assim, se  $i$  for dominado por um número  $n$  de indivíduos, é atribuído a  $g_{d,i}$  o valor  $n$ . Se, ao fim do processo de comparação, o valor de  $g_{d,i}$  for zero, indicará que o mesmo não é dominado dentro da população e consequentemente faz parte do grupo de possíveis candidatos que comporão a frente de Pareto. O processo pode ser estendido para as demais frentes ( $n \neq 0$ ), se houver necessidade. O raciocínio explanado é resumido no Algoritmo 2.

---

#### Algoritmo 2: FAST NON-DOMINATED SORTING

---

```

1 para cada  $i \in$  população fazer
2   para cada  $j \in$  população fazer
3     se  $j$  domina  $i$  então
4       Incrementa  $g_{d,i}$ 
5     fim
6   fim
7 se  $g_{d,i} = 0$  então
8   Armazena  $i$ 
9 fim
10 fim

```

---

Do conjunto de indivíduos não-dominados (candidatos à frente de Pareto), é escolhida uma amostra do tamanho da população definida no algoritmo e que representa a próxima geração. Este mecanismo de escolha é exposto nas próximas linhas.

### 4.3.2 Crowding Distance

O *Crowding Distance* é o operador que insere diversidade ao NSGA-II com o objetivo de gerar mais pluralidade de soluções dentro da frente de Pareto. A partir de um artifício geométrico, evita-se selecionar soluções dentro de concentrações populacionais densas. Como métrica, o *Crowding Distance* utiliza a distância entre os indivíduos mais próximos. Como é discutido a seguir.

Dados três indivíduos com características  $\zeta_{i-1}$ ,  $\zeta_i$ ,  $\zeta_{i+1}$  e armazenados no processo de *Fast Non-Dominated Sorting*, são calculadas as distâncias entre  $\zeta_{i-1}$  e  $\zeta_{i+1}$  nas direções horizontal ( $|f_{Obj1}(\zeta_{i+1}) - f_{Obj1}(\zeta_{i-1})|$ ) e vertical ( $|f_{Obj2}(\zeta_{i+1}) - f_{Obj2}(\zeta_{i-1})|$ ). Estes dois valores são introduzidos em uma métrica similar ao *Hypervolume* (ZITZLER, 1999). Nesta métrica, o produto das distâncias (Eq. 4.2) que denotam os afastamentos horizontal e vertical entre as partículas de características  $\zeta_{i+1}$  e  $\zeta_{i-1}$ , é tomado como parâmetro indicador de concentração populacional na vizinhança do indivíduo  $i$ . Assim, para cada indivíduo não-dominado (candidato à frente de Pareto) calcula-se o *Hypervolume* e, ao fim desta operação, é escolhida uma amostra (do tamanho da população exigida pelo algoritmo), com os indivíduos de *Hypervolume*

mais elevados. Este critério evita que regiões densamente povoadas, com indivíduos de baixo *Hypervolume*, permaneçam na frente, o que poderia viciá-la com características ineficientes. É importante também enfatizar que os dois indivíduos nos extremos do ordenamento (crescente em termos de  $f_{Obj1}$  ou  $f_{Obj2}$ ) são sempre escolhidos para fazerem parte da frente, já que os seus *Hypervolumes* são “infinitos”. O leitor está coerente em se perguntar o porquê da terminologia *Hypervolume* se neste exemplo efetivamente avalia-se a área. O fato é que em (ZITZLER, 1999), a definição é feita com produto das distâncias de tantas quantas forem as funções objetivos usadas, como definido na Equação 4.2, o que inclui o caso tridimensional (volume).

$$V_i = \prod_{n=1}^p |f_{Obj_n}(\zeta_{i+1}) - f_{Obj_n}(\zeta_{i-1})|. \quad (4.2)$$

Por  $p$  entende-se o número de objetivos usados no problema. A descrição mais detalhada do raciocínio apresentado é exposta no Algoritmo 3.

---

**Algoritmo 3:** CROWDING DISTANCE

---


```

1 para cada  $i$  tal que  $g_{d,i} = 0$  e  $i \neq 0, l$  fazer
2   |   calcula-se  $V_i$ 
3 fim
4 se  $i = 0$  ou  $i = l$  então
5   |    $V_i =$  Valor muito alto
6 fim
7 devolver  $N$  indivíduos com os maiores valores de Hypervolume

```

---

**Figura 19** – Representação gráfica do *Hypervolume* para duas dimensões.



Fonte: o autor.

Tendo em vista a apresentação detalhada dos conceitos que dão fundamento ao NSGA-II, parte-se agora para uma etapa de averiguar o uso da técnica em cenários de transmissão óptica.

Com o intuito de mostrar o êxito da aplicação da meta-heurística, faz-se necessária a comparação desta com ferramentas de programação matemática, assim como foi feito com o PSO. Assim, a próxima seção abordará a construção do cenário de otimização que se deseja estudar.

#### 4.4 Uma perspectiva para tratamentos tradicionais

O problema de otimização de potência e arranjo espectral com o objetivo de mitigar a influência da não-linearidade foi detalhado em (PALKOPOULOU et al., 2013) e (J.ZHAO; H.WYMEERSCH; E.AGRELL, 2015). Nestes trabalhos propõe-se, contudo, a otimização dos recursos de forma separada, o que responde parcialmente às deficiências encontradas em cenários realistas. No entanto, em (YAN et al., 2015) encontra-se uma sugestão de tratamento destes recursos de forma conjunta. Neste trabalho, como será visto mais adiante, o uso de formulação MINLP (do inglês, *Mixed Integer Nonlinear Programming*) é previsto para um manuseio eficiente de perfis de potência e arranjo espectral, o qual será contrastado com o resultado via GA.

Para análise da técnica, desenha-se uma topologia de rede idêntica à Fig. 8 com 6 canais  $A$  (200 Gbps) e 5 canais  $B/B^+$  (250 Gbps), dispostos de forma agrupada como na Fig. 14. Neste cenário é possível alterar a potência de cada canal e a banda ao modificar a modulação individualmente. Como o objetivo principal desta manipulação matemática é garantir QoT para todas requisições, é necessário que a seguinte desigualdade seja obedecida:

$$OSNR_i(\mathbf{c}, \mathbf{f}, \mathbf{G}) \geq OSNR_{Th}(c_i) \quad (4.3)$$

Aqui,  $OSNR_i(\mathbf{c}, \mathbf{f}, \mathbf{G})$  é a OSNR calculada em um canal  $i$  como função dos possíveis formatos de modulação ( $\mathbf{c}$ ), frequências centrais ( $\mathbf{f}$ ) e densidade espectral de potência ( $\mathbf{G}$ ). Assim, como forma complementar, alguns objetivos alvos no tratamento de otimização em redes ópticas também precisam ser incluídos, são eles:

- minimizar banda total ocupada pelos canais,
- minimizar potência total,
- maximizar mínima margem de OSNR,
- maximizar soma das margens de OSNR.

O tratamento multiobjetivo ponderado destas variáveis é formulado em (YAN et al.,

2015), a partir de:

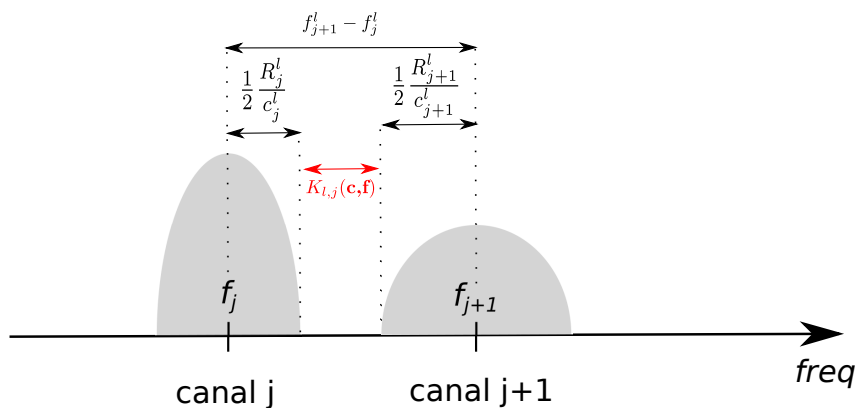
$$\begin{aligned}
 & \underset{\mathbf{c}, \mathbf{f}, u, t_{min}}{\text{minimizar}} && \theta_1 u + \theta_2 \sum_{i \in D} \frac{R_i}{c_i} G_i + \theta_3 t_{min} + \theta_4 \sum_{i \in D} t_i \\
 & \text{submetido a} && t_i \leq 1, \forall i \in D, \\
 & && \mathbf{K}_l(\mathbf{c}, \mathbf{f}) \geq 0, \forall l \in E, \\
 & && u \geq \frac{R_i}{2c_i} + f_i, \forall i \in D, \\
 & && t_{min} \geq t_i, \forall i \in D,
 \end{aligned} \tag{4.4}$$

onde  $u$  é a frequência do limite superior do último canal (neste caso de ordem igual 11),  $t_i$  é o inverso da margem de OSNR em escala linear para o  $i$ -ésimo canal e  $t_{min}$  representa o inverso da mínima margem de OSNR dentro do conjunto de canais (neste caso, os 11 canais). Além disto,  $c_i$  representa a eficiência espectral da modulação do  $i$ -ésimo canal. Por fim,  $E$  representa o conjunto de todos os links usados da rede e  $D$  é o conjunto de canais.

Para que seja inserida a condição de não-sobreposição de canais, na formulação foi adicionada a variável não-negativa  $\mathbf{K}_l(\mathbf{c}, \mathbf{f}) = (K_{l,1}(\mathbf{c}, \mathbf{f}), \dots, K_{l,D_l-1}(\mathbf{c}, \mathbf{f}))$ , dada pela Equação 4.5 e graficamente pela Fig. 20. Esta variável representa o espaçamento espectral entre dois canais vizinhos.

$$K_{l,j}(\mathbf{c}, \mathbf{f}) = f_{j+1}^l - f_j^l - \frac{1}{2} \left( \frac{R_j^l}{c_j^l} + \frac{R_{j+1}^l}{c_{j+1}^l} \right) \tag{4.5}$$

**Figura 20** – Espaçamento espectral para a condição de não-sobreposição dos canais.



Fonte: o autor.

Se o leitor perceber, cada uma das condições de otimização é atendida pelo termo que acompanha  $\theta_1, \theta_2, \theta_3$  e  $\theta_4$ . Para minimizar a banda total ocupada pelos canais, utiliza-se a variável  $u$ . Já para minimizar a potência total gasta, faz-se o somatório do produto banda ( $\frac{R_i}{c_i}$ ) por densidade espectral de potência ( $G_i$ ) para todos os canais  $i \in D$ . Por fim, o inverso da OSNR de cada canal é representado pela variável  $t_i$ , o que permite trabalhar com a minimização desta para ter-se uma maximização de OSNR. Assim, é levado em consideração não somente o impacto da

OSNR de todos os canais ( $\sum_i t_i$ ) como também a influência do mínimo valor ( $t_{min}$ ). Manipular a OSNR permite melhorar a robustez e capacidade da rede.

Um dos pontos a serem questionados em (YAN et al., 2015) é o fato de que métodos de progração matemática são deficientes, em comparação a métodos evolucionários, quando em abordagens multiobjetivas. Ao olhar bem para formulação 4.4, vê-se que o objeto de otimização é uma única expressão com objetivos ponderados mas que resultará em apenas uma solução. Estas características fogem da pluralidade de possibilidades desejadas em redes ópticas e que é bem atendida pelo conceito de ótimo de Pareto presente no NSGA-II. Isto ficará claro nas comparações feitas adiante.

A ferramenta matemática utilizada para a solução de 4.4 é o BONMIN (BONAMI et al., 2018), um solucionador MINLP genérico que trabalha dividindo recursivamente o espaço de soluções do problema original em subconjuntos menores onde subproblemas são formulados. Um relaxamento convexo ou aproximação externa (BONAMI; KILINC; LINDEROTH, 2012) de cada subproblema é resolvido para fornecer um limite inferior da solução para esse subconjunto, enquanto um limite superior é obtido por uma solução ótima. O intervalo entre o maior limite inferior e o menor limite superior dentre todos os subproblemas é chamado de gap de otimalidade, que indica a convergência e pode ser usado como um critério de parada.

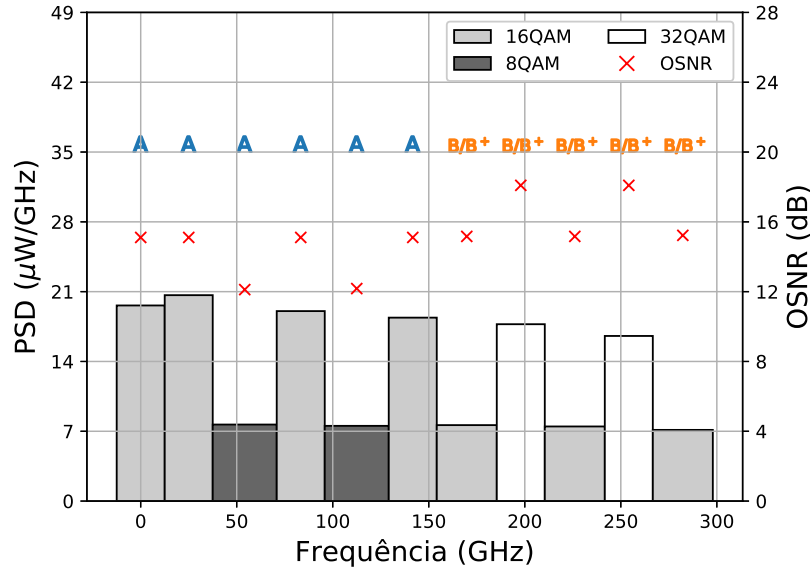
Para uma primeira demonstração dos resultados obtidos pela formulação MINLP, utiliza-se a topologia de rede previamente introduzida no início desta seção. Nesta primeira abordagem, deseja-se apenas verificar qual seria o perfil encontrado na Fig. 14 se a manipulação de banda, através da mudança de formato de modulação, fosse incluída. Para isto, os pesos foram determinados tais que:  $\theta_1 = 1, \theta_2 = 0, \theta_3 = 10^{-3}, \theta_4 = 10^{-3}$ . Vale ressaltar que a escolha destes parâmetros poderia ser binária (0 ou 1), no entanto, o autor fez diferente para “balancear” as parcelas. Por fim, as propriedades físicas da rede são sumarizadas na Tabela 2 e o modelo de propagação não-linear é o (JOHANNISSON; AGRELL, 2014).

**Tabela 2 – Parâmetros Físicos da Rede**

Numero de Spans	12
Comprimento do Span	100 km
Coef. de disp. cromática de segunda ordem	$-2,13 \times 10^{-24} \text{ s}^2 \cdot \text{km}^{-1}$
Coefficiente não-linear	$1,3 \text{ W}^{-1} \cdot \text{km}^{-1}$
Coefficiente de atenuação	$0,22 \text{ dB} \cdot \text{km}^{-1}$
Figura de Ruído do Amplificador	3 dB

Como é perceptível na Fig. 21, o gráfico mostra que a solução ótima para a formulação utilizada permite que modulações de menor eficiência espectral sejam utilizadas. Este é um meio de garantir a maximização da soma de OSNR dos canais e conseqüentemente permitir que estes trafeguem mais longe. Como meio de minimizar a banda, a formulação retorna um resultado em que  $\mathbf{K}_l(\mathbf{c}, \mathbf{f}) = 0, \forall l \in E$ . Esta característica é importante pois mostra que as desvantagens em permitir uma banda de guarda mínima para reduzir a não-linearidade podem ser compensadas

**Figura 21** – Perfil de densidade espectral de potência e arranjo espectral ótimo para formulação MINLP.



Fonte: o autor.

através do manuseio eficiente da potência. O mesmo raciocínio foi construído com o NSGA-II e será comparado na seção a seguir.

#### 4.5 GA como ferramenta de otimização

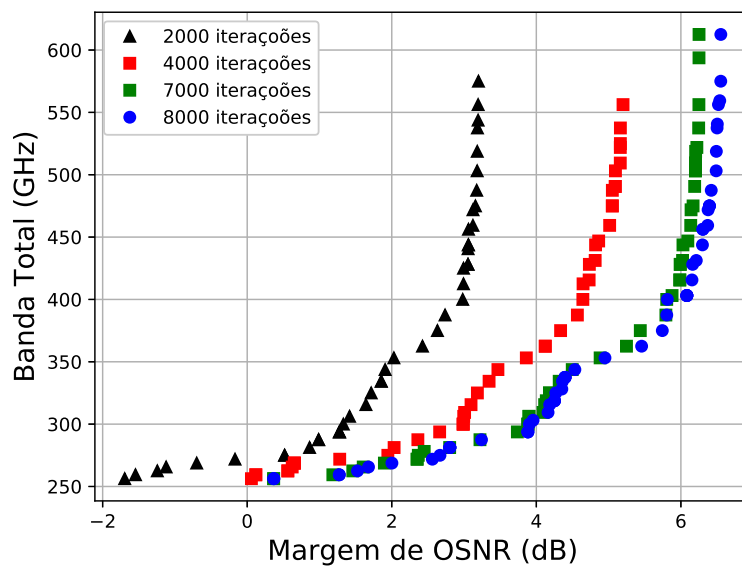
Nesta etapa buscou-se retratar a multiobjetividade de (YAN et al., 2015) com as relações de compromisso do NSGA-II ao invés de criar uma otimização mono-objetiva por pesos. Como primeiro cenário, pensou-se em contrastar mínima margem de OSNR com banda total utilizada, onde a ideia é maximizar a primeira e minimizar a segunda. Se o leitor perceber, esta conexão entre as duas variáveis é contraditória pois quando há redução de banda recorre-se a modulações mais eficientes, que conseqüentemente possuem limiar de OSNR mais elevado e assim diminuem margem.

Neste primeiro caso, a ênfase é em cima da mutação realizada pelo GA, pois é durante esta operação que os perfis espectrais e de potência são alterados. O raciocínio utilizado neste caso foi de que cada gene possui uma probabilidade de mutação ( $Pr_M$ ) de 40%. Dentro desta probabilidade existem três possibilidades de mudanças: a de somente potência ser alterada, somente modulação ser alterada e de potência e modulação serem alteradas em paralelo. Para as duas primeiras possibilidades, foi dada uma probabilidade de 40%, enquanto que para a última foi de 20%.

Para alterar a modulação, o operador “sorteia” um dos quatro possíveis níveis de modulação permitidos: PM-4QAM, PM-8QAM, PM-16QAM e PM-32QAM. Já para alterar a potência, um raciocínio mais delicado foi pensado. Como a escolha de uma ordem de grandeza

de centésimos de miliwatts ( $10^{-5}W$ ) foi usada para gerar as potências iniciais dos canais (na etapa de Geração Inicial da População), foi realizado um mecanismo que adiciona/subtrai um  $\delta_P$ , gerado aleatoriamente e da ordem de décimos de microwatts ( $10^{-7}W$ ), ao valor de potência do canal. Este mecanismo permite dar maior acurácia à discretização dos passos, contudo, aumenta moderadamente o tempo de processamento computacional. Neste caso, não restringiu-se a potência total dos canais e foram analisados perfis para 2000, 4000, 7000 e 8000 iterações. A Fig. 22 representa esta análise.

**Figura 22** – Frentes de Pareto para otimização: banda x mínima margem de OSNR.



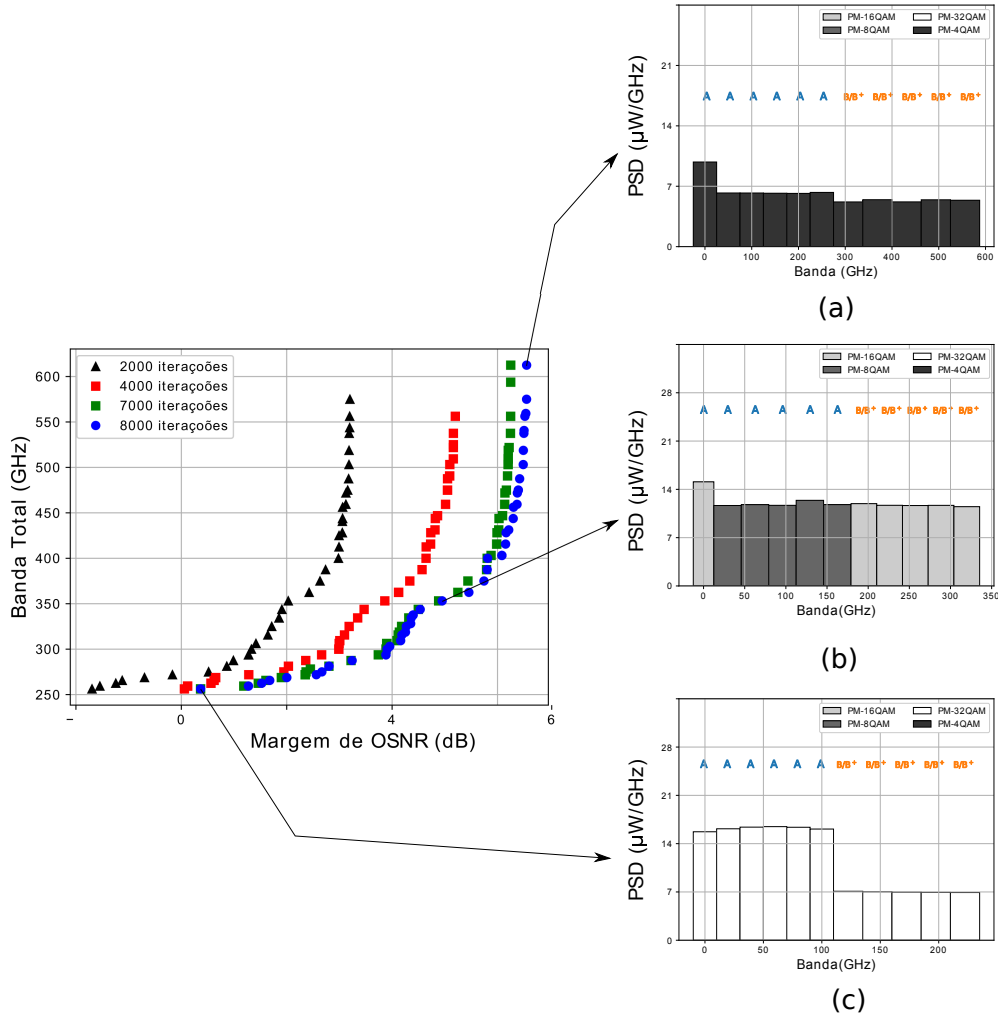
Fonte: o autor.

Como é possível identificar em Fig. 22, apesar de a curva de 2000 iterações ser solução durante determinado ponto da simulação, ela possui indivíduos com mínima margem de OSNR negativa (em dB), o que indica que o canal mais penalizado pela não-linearidade não tem OSNR suficiente para superar o limiar necessário. Isto é fruto dos valores de inicialização de potência (da ordem de centésimos de mW) em que abunda o regime do ruído ASE. A curva de 4000 iterações, pelo contrário, indica que todos os indivíduos já venceram a barreira do limiar de OSNR, visto que a mínima margem é positiva. Outro aspecto atrativo é a pluralidade de soluções, que é investigada mais a fundo na Fig. 23.

A curva obtida está dentro do comportamento esperado. A intenção desta análise é maximizar a mínima margem de OSNR e minimizar a banda total utilizada pelo conjunto de canais. Portanto, era esperado que as frentes de Pareto convergissem para o extremo direito inferior do plano.

Três perfis são tomados para análise da solução obtida na Fig.22. O primeiro perfil é o que prioriza (maximiza) o recurso mínima margem de OSNR, ou seja, o de solução mais à direita e mais acima da Fig. 22 e investigado na Fig. 23.a. Esta solução permite que modulações

**Figura 23** – (a) Indivíduo que prioriza mínima margem. (b) Indivíduo com perfil intermediário. (c) Indivíduo que prioriza banda.



Fonte: o autor.

mais robustas (PM-4QAM) sejam as únicas utilizadas para garantir QoT. Outra característica importante é a distribuição das potências. Se o leitor perceber, verá que o perfil de potências para esta solução não tem uma natureza tão contínua e suave como os perfis atingidos pelo PSO. Esta característica é fruto do mecanismo de mutação processado pelo GA, que permite que descontinuidades, como a do canal 1, persistam nas soluções.

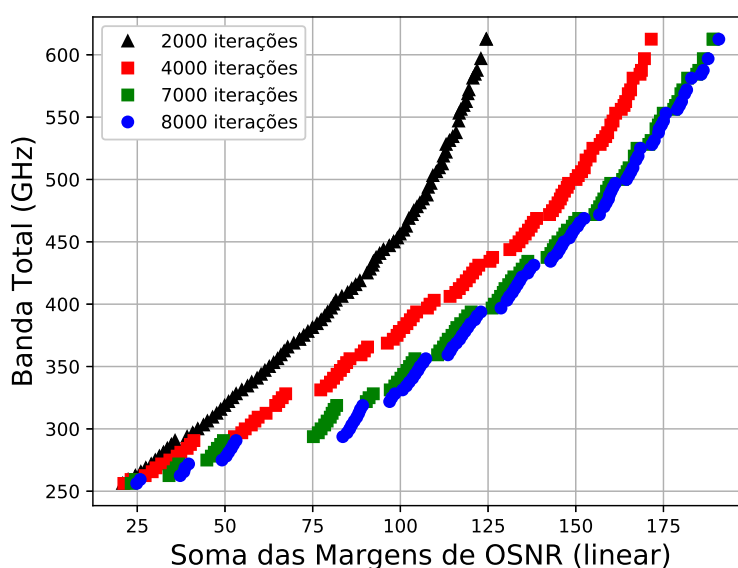
O segundo perfil estudado é o que minimiza a banda total utilizada, Fig 23.c. Neste, o leitor percebe que o conjunto é uniformemente preenchido por canais PM-32QAM. Este resultado, por outro lado, tem uma mínima margem crítica de se trabalhar já que o limiar de OSNR desta modulação é elevado. Outra característica adicional e que também permite a existência deste perfil é o arranjo de potências. Era esperado que os canais A possuíssem potência mais elevada do que os canais B/B<sup>+</sup> (como meio de equalizar as densidades espectrais de potência) e isto é constatado.



O terceiro e último perfil, Fig.23.b, é o que indica uma relação intermediária dos objetivos que se almejam otimizar. Neste, fica mais clara a característica de alocação de canais mais eficientes (em termos de modulação) apontada em (NAKASHIMA et al., 2015), isto é, modulações mais eficientes precisam ser alocadas no extremo do espectro, o que justifica a predominância de PM-16QAM para os extremos dos canais  $A$  e  $B/B^+$ . Se for analisado, os  $B/B^+$  (6 spans) trafegam distâncias mais curtas, que possibilita o uso de modulações mais eficientes, logo, todos esses integrantes conseguem ser PM-16QAM. Por outro lado, os canais  $A$  percorrem mais spans, por isso, são de predominância PM-8QAM. Foi permitido ao canal de ordem 1 assumir uma modulação mais eficiente, já que a não-linearidade nesta zona (extremo) é mais branda.

Num segundo momento, a relação de compromisso é observada quando contrastam-se banda total utilizada com soma das margens de OSNR. Esta última é uma medida tomada com o intuito de garantir aumento da média de OSNR de todos os canais. Assim, o objetivo agora é verificar as peculiaridades do perfil quando busca-se maximizar a soma das margens de OSNR e minimizar banda. Este comportamento é retratado na Fig. 24.

**Figura 24** – Frentes de Pareto para otimização: banda x soma das margens de OSNR.



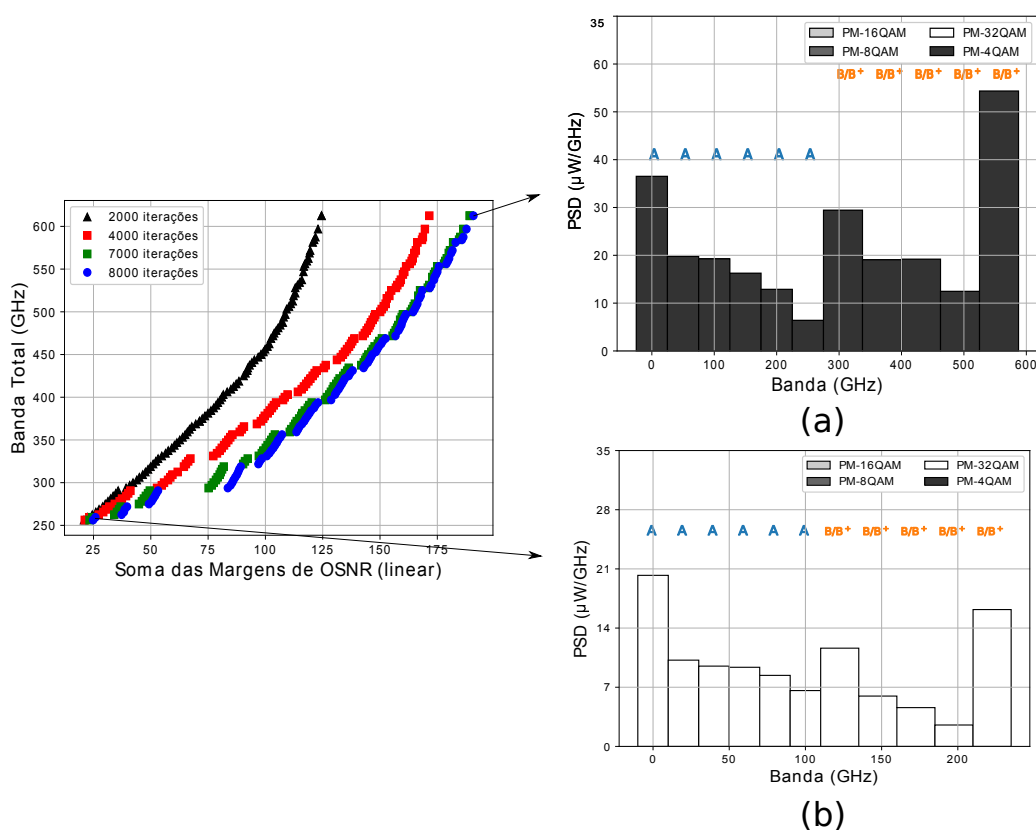
Fonte: o autor.

Quando o leitor compara as curvas com o exemplo anterior, percebe uma concentração maior de soluções na frente de Pareto deste último caso. Isto deve-se ao fato de a soma das margens de OSNR deixar a abordagem menos seleta pois admite configurações em que, por exemplo, um canal esteja bastante penalizado enquanto os outros 10 estejam com folga razoável de OSNR. No caso em que se avalia a maximização da mínima margem, por outro lado, esta configuração provavelmente já teria sido descartada. Além disto, novamente percebe-se o comportamento das frentes de Pareto em direção à direção sudeste do plano. Isto pois a intenção desta análise é

maximizar a soma das margens OSNR bem como minimizar a banda total utilizada.

Uma investigação mais profunda dos indivíduos gerados nesta simulação confirma o raciocínio levantado no parágrafo anterior. Ao olhar para a Fig. 25.a, vê-se que a solução com maior soma total de margem é simplesmente a configuração com todos os canais PM-4QAM, o que indica a total concordância com o esperado, visto que a abordagem tenta distribuir margem de OSNR para todos os canais ao invés de olhar para o mais atacado pela não-linearidade. Como consequência disto, os valores de potência não são tão uniformes como no primeiro cenário, pois o que interessa para esta análise é a média das margens, o que acarreta na negligência a valores de potência demasiadamente altos ou baixos, o que cria perfis em escada para os dois extremos da frente (Fig. 25.a e 25.b).

**Figura 25** – (a) Indivíduo que prioriza soma das margens. (b) Indivíduo que prioriza banda.




Fonte: o autor.

É nítido perceber que as duas análises até agora percorridas agregam características importantes às soluções. Enquanto a primeira é mais seletiva e se preocupa em garantir qualidade à demanda mais penalizada, a segunda concentra-se em distribuir recursos para ser mais justa. Uma pergunta interessante é: como a análise se daria se todas estas variáveis fossem levadas em consideração, isto é, banda, mínima margem de OSNR e soma das margens? A resposta deste questionamento atrela a si a possibilidade de comparação com o método utilizado em (YAN et al., 2015).

Neste próximo cenário, a análise conjunta dos três objetivos efetivamente considerados em (YAN et al., 2015) é feita sob a perspectiva da otimização genética. Nesta análise, é possível abstrair o uso de parâmetros  $\theta_1, \theta_2, \theta_3$  ou  $\theta_4$ , utilizados na literatura, e há a vantagem de entender as soluções como uma relação de compromisso. A Fig. 26 mostra um estudo dos resultados para 4 valores de iteração: 4000, 8000, 16000 e 20000. Não há avanço efetivo da frente com 16000 iterações para a de 20000, o que foi considerado como condição de parada. Adicionalmente, o leitor consegue perceber que a evolução das frentes (superfícies) compõem curvas que fluem no sentido de maximizar a mínima margem e a soma das margens, bem como minimizar a banda total ocupada pelos canais. Outra característica interessante é o crescimento da mínima margem de OSNR, que inicialmente começa negativa, o que indica violação do limiar necessário para transmissão. Contudo, a última curva já expõe maioria dos indivíduos com mínima margem positiva, os quais podem ser efetivamente considerados soluções candidatas.

**Figura 26** – Evolução das frentes de Pareto com o número de iterações.



Fonte: o autor.

Como etapa de validação, foram comparadas as soluções obtidas via NSGA-II com aquelas frutos da formulação MINLP multiobjetiva de (YAN et al., 2015), apresentada na Fig. 21, e a PSO mono-objetiva desenvolvida na Seção 3.4, mais precisamente na Fig.14, visto que todas trabalham no mesmo cenário de tráfego. Este contraste entre soluções é observado na Fig. 27, onde os marcadores vermelhos indicam as soluções obtidas com o NSGA-II, os azuis a formulação MILP (otimizando mínima margem de OSNR, soma das margens e banda) e os verdes o PSO (otimizando mínima margem). Alguns comentários devem ser tecidos sobre os

resultados expostos. Para melhor visualizar a precisão de alguns pontos, a Tabela 3 foi necessária.

**Tabela 3** – Comparação quantitativa das funções objetivo de indivíduos oriundos NSGA-II com demais técnicas tratadas neste trabalho.

Solução	Parâmetros de otimização		
	Soma das Margens de OSNR (linear)	Banda Total Utilizada (GHz)	Mínima Margem de OSNR (dB)
NSGA-II (priorizando soma das margens)	162,50	612,5	4,30
NSGA-II (priorizando mínima margem)	162,50	612,5	4,30
NSGA-II (priorizando banda)	106,62	425,00	0,14
Yan et. al., MINLP	11,86	312,50	0,33
PSO	16,73	566,25	1,82


Fonte: o autor.

Três pontos da frente de Pareto foram utilizados para comparação com os outros dois resultados obtidos anteriormente. Como é possível identificar, o ponto que prioriza margem e o ponto que prioriza soma das margens são o mesmo. Esta solução permite que o pior canal possua uma mínima margem de 4,30 dB, o que garante que, de todas as soluções, esta é a que permite todos os canais trafegarem o mais distante possível. Por outro lado, a banda total ocupada por esta solução chega a 612,5 GHz, o que torna a usabilidade do espectro pouco eficiente para a transmissão dos 2,45 Tbps requeridos.

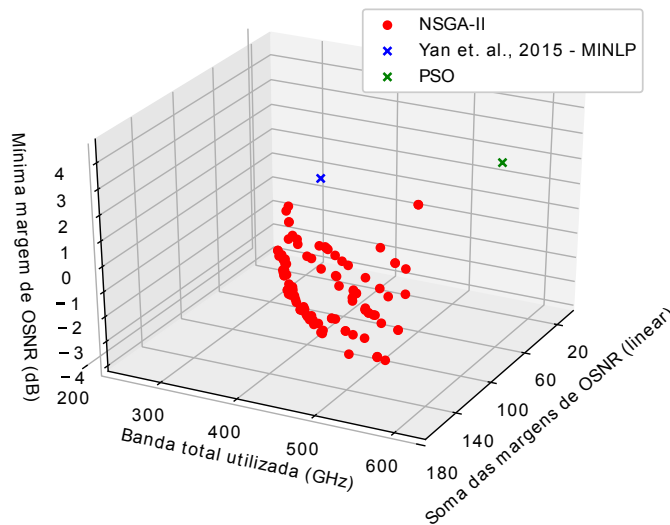
Quando a solução que prioriza banda é o foco, vê-se que esta trabalha com pelo menos um canal prestes a infringir o limiar de OSNR, ou seja, com uma margem consideravelmente baixa (0,14 dB). As soluções do NSGA-II permitem outros indivíduos com mínima margem negativa (em dB), o que é facilmente verificado na Fig. 27, no entanto, estas soluções são descartadas para efeito de comparação e concentra-se a análise em resultados que permitam a existência de todos canais sem violação do limiar de OSNR.

Se o resultado obtido por (YAN et al., 2015) for colocado em prova, alguns pontos de reflexão são levantados. À priori, o leitor questionará o porquê de a solução evolucionária ter achado alguns resultados que dominam o oriundo de formulação MINLP se este promete ser ótimo. A resposta está atrelada à filosofia de otimização. Este trabalho concentra suas energias em propor um método que independa do uso de qualquer tipo de parâmetro e tenha a vantagem de permitir uma análise de *trade-off* entre as variáveis a serem otimizadas. Enquanto isso, o encontrado na literatura impõe o uso de coeficientes não otimizados e disfarça uma análise mono-objetiva ao tratar as variáveis por uma média ponderada. É importante destacar que o

**Figura 27** – (a) Comparação NSGA-II sob perspectiva 1. (b) Comparação NSGA-II sob perspectiva 2.



(a)



(b)

Fonte: o autor.

resultado exposto em (YAN et al., 2015) continua sendo ótimo para o ambiente de otimização preestabelecido por ele, o qual mereceu ser reformulado. Em (YAN et al., 2015), percebe-se que as margens de OSNR de cada canal são muito tênues, visto que a mínima margem é um valor baixo (0,33 dB), mas positivo, o que viabiliza a transmissão de todos os canais. Além disso, a soma das margens também não tem tanta expressividade (11,86). Quando a priorização de banda é levada em conta, apesar de o valor assumido pela formulação MINLP ser inferior ao do evolucionário (PSO), o que indica uma vantagem, a mínima margem deste último é superior ao resultado obtido pelo MINLP.

Por último compararam-se também os dois resultados evolucionários, isto é, entre o PSO

(exposto no Capítulo 3) e o aqui desenvolvido. É importante lembrar que o perfil de modulações utilizados no PSO foi sugerido em (IVES; SAVORY, 2013), mas não passou por qualquer otimização formulada em termos de banda, apenas sugeriu-se uma configuração que satisfizesse as condições de margem e usasse uma faixa menor do espectro com mais taxa de bits. Percebe-se neste uma enorme desvantagem em termos de banda. Isto se dá pois no PSO usou-se banda de guarda (25GHz) entre os canais como meio de suavizar a não-linearidade. Em termos de mínima margem, foi obtido um valor de 1,82 dB, valor moderado, já que o único objetivo desta formulação era otimizar esta variável em detrimento das outras.

#### 4.6 Otimizando o arranjo espectral

Se o leitor percebeu, os cenários trabalhados se limitam muito em termos de arranjo espectral. Até o momento, nenhuma possibilidade de alteração da ordem dos canais foi proposta neste capítulo ou na literatura aqui referenciada. Sempre foi usado o arranjo fixo com os 6 primeiros canais satisfazendo o caminho  $A$  e os cinco últimos o caminho  $B/B^+$ . No Capítulo 3, existe a sugestão de se trabalhar com busca exaustiva seguida de otimização evolucionária, contudo, esta torna-se inviável no contexto aqui exposto. Como solução, este trabalho usa o recurso da operação de mutação para variar a ordem das demandas  $A$  e  $B/B^+$ .

Suponha que cada indivíduo candidato a ser solução do problema tenha apenas 6 canais do tipo  $A$  e 5  $B/B^+$ . A ordem destes canais é livre para ser alterada seguindo a seguinte política. Durante o processo de mutação, cada gene tem a chance de ter sua distribuição espacial de tráfego alterada, isto é, se irá seguir o caminho  $A$  ou  $B/B^+$ . A probabilidade deste evento acontecer para cada gene é de 40%. O leitor logo questionará que, se este procedimento for tomado, indivíduos com demandas de tráfego bem diversas da que se deseja fixar ( $6A + 5B/B^+$ ) vão surgir, por exemplo:  $7A + 4B/B^+$ ,  $11A + 0B/B^+$ , etc. É neste momento que se altera o procedimento de *Crowding Distance* para restringir o problema. No entanto, antes é necessário introduzir uma nova variável ( $R_i$ ) que cada indivíduo  $i$  receberá.

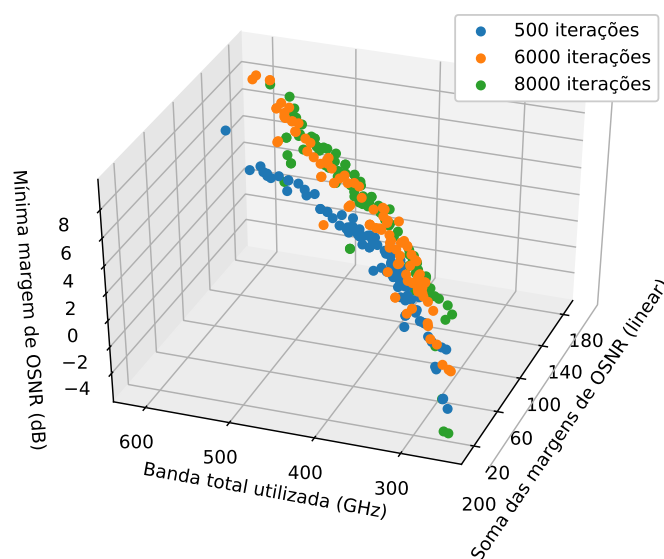
$$R_i = \frac{n_A}{n_{B/B^+}} \quad (4.6)$$

Por  $R_i$  entende-se a razão do número de canais com demanda  $A$  ( $n_A$ ) com relação ao número de canais com demanda  $B/B^+$  ( $n_{B/B^+}$ ). Como as soluções que atendem a restrição de ter apenas 6 canais do tipo  $A$  e 5  $B/B^+$  têm razão 6/5, o que numericamente equivale a 1,2, indivíduos com este valor de  $R_i$  terão prioridade no processo de *Crowding Distance*. Esta prioridade expressa-se através de ligeira modificação da métrica de Hypervolume, que agora será escrita da seguinte forma:

$$V_i = \frac{\prod_{n=1}^p |f_{Obj_n}(\zeta_{i+1}) - f_{Obj_n}(\zeta_{i-1})|}{\epsilon + 1,2 - R_i} \quad (4.7)$$

onde  $\epsilon$  é um número muito pequeno, usado apenas para o denominador não anular. Assim, soluções que atendam a restrição imposta serão priorizadas no processo de elitismo para participar da frente de Pareto. O resultado da implementação desta característica pode ser observado a partir da Fig. 28.

**Figura 28** – Evolução das frentes de Pareto para NSGA-II proposto (Perspectiva 1).



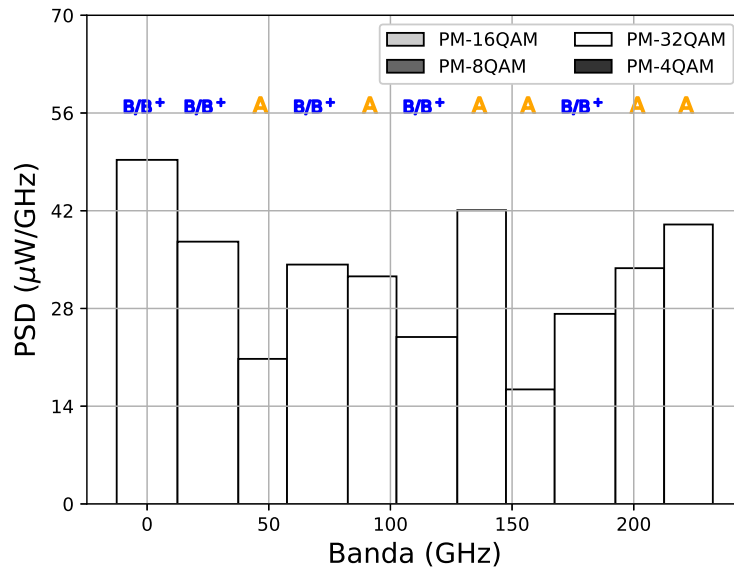
Fonte: o autor.

Como é possível identificar de imediato, com esta alteração, a cobertura da superfície (frente de Pareto) permite uma maior expansão em termos de área do que no caso em que o arranjo das demandas é fixo. Esta mobilidade, em termos de arranjo, viabiliza uma exploração mais eficiente do espaço de buscas e conseqüentemente implica na descoberta de soluções ainda mais próximas do ótimo. Outra característica importante é o crescimento efetivo da quantidade de indivíduos com mínima margem de OSNR elevada. Uma investigação das soluções permite identificar perfis.

Primeiro busca-se entender qual o perfil que prioriza a minimização da banda total. A Fig. 29 mostra novamente que o espectro completamente preenchido por canais PM-32QAM não perde o título de solução mais apta a este requisito. Outro aspecto importante é o perfil não-constante encontrado na densidade espectral de potência, característica certamente herdada da otimização da soma das margens como visto anteriormente na Fig. 25. Quanto à nova análise de disposição dos canais, percebe-se que a alternância de canais com demandas de tráfego diferentes, como previamente constatado em Fig. 11, atua como uma blindagem para coexistência de canais conjugados.

Também é inspecionado o perfil que maximiza a mínima margem de OSNR, o qual novamente coincide com o mesmo perfil que tem a máxima soma das margens. Como a Fig. 30 expõe, para garantir a robustez em termos de margem, soluções com modulação menos

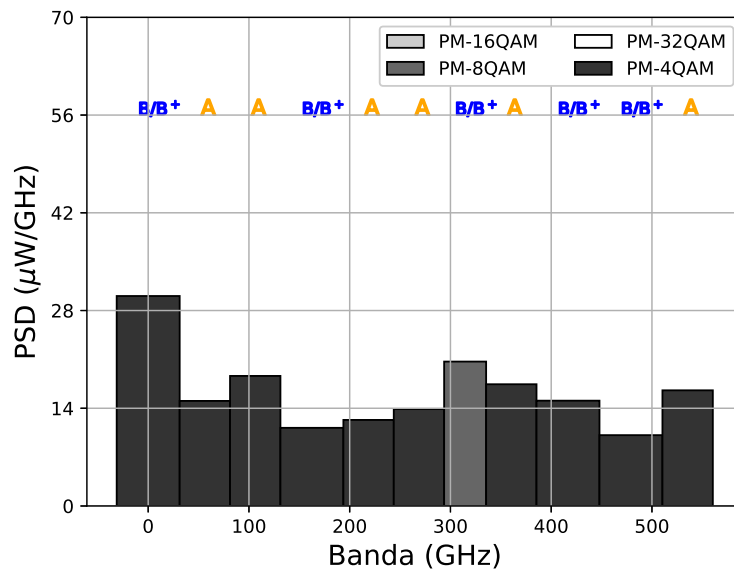
**Figura 29** – Indivíduo que prioriza banda.



Fonte: o autor.

eficientes são vitais, por isso o uso de canais PM-4/8QAM. Novamente, identifica-se o perfil alternado em termos de demanda de tráfego.

**Figura 30** – Indivíduo que prioriza mínima margem.

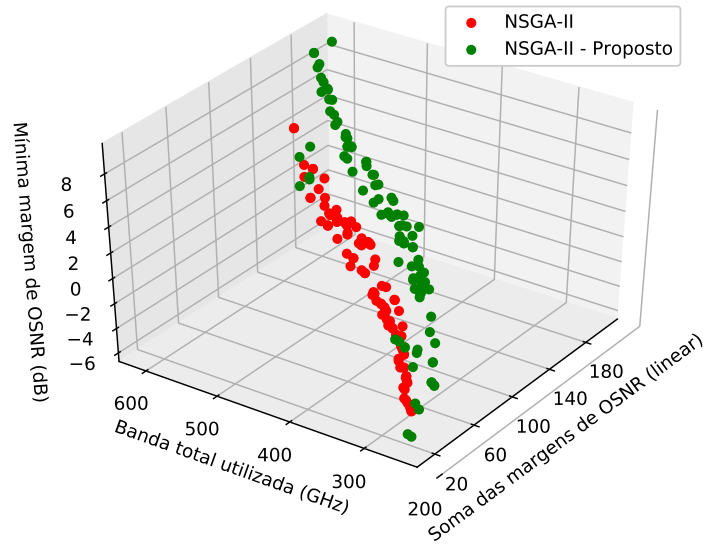


Fonte: o autor.

Como é possível observar, adicionalmente, a superfície obtida nesta última otimização possui uma densidade alta de indivíduos acumulados na direção espacial que maximiza mínima margem bem como soma das margens. No entanto, é sabido que a minimização da banda também é um fator importante nesta análise o que se traduz em um acúmulo moderado em região onde a

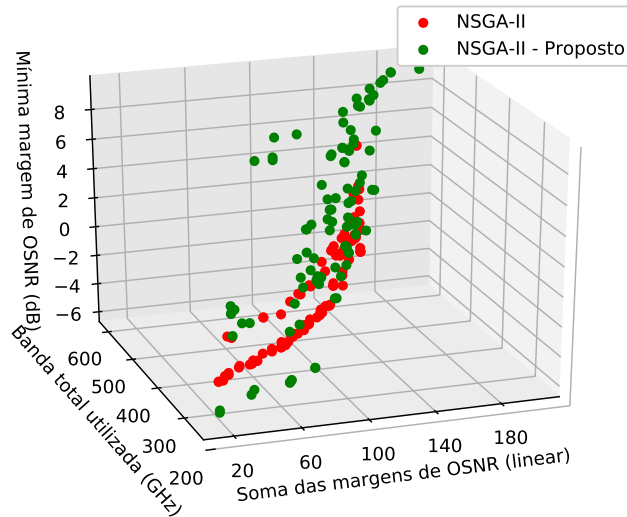


**Figura 31** – Comparação entre NSGA e NSGA-II Proposto (Perspectiva 1).



Fonte: o autor.

**Figura 32** – Comparação entre NSGA e NSGA-II Proposto (Perspectiva 2).



Fonte: o autor.

ocupação do espectro desfavorece o quesito margem de OSNR.

Para validar esta tratativa, esta versão proposta do NSGA-II foi contrastada com os resultados obtidos na Fig. 27. A análise desta comparação é vista na Fig. 31 e em Fig. 32, em que é possível constatar que as soluções obtidas pela nova tratativa (NSGA-II Proposto) estão em uma frente consideravelmente mais avançada, garantindo assim, indivíduos mais eficientes. Isto mostra que a simples permuta na posição das demandas consegue explorar o espaço de buscas

com mais eficiência e reformula a análise proposta em (YAN et al., 2015) de uma maneira mais apropriada e plural. Este resultado também funciona como uma alternativa à proposta de busca exaustiva introduzida em (IVES; SAVORY, 2013) que fica inviabilizada quando a mobilidade do uso hetergêneo de modulações é levada em consideração.

## 5 CONCLUSÃO

O uso de canais ópticos elásticos promete saciar as demandas e cenários de conectividade que se constroem para o futuro das comunicações. O domínio das técnicas de gerência de recursos é um dos principais focos de estudo em comunicações ópticas, que fomentam e promovem desenvolvimento de tecnologias mais sofisticadas de transmissão. Aliado a isto, o surgimento crescente de técnicas de inteligência artificial na otimização de problemas de engenharia tem desviado o foco de ferramentas tradicionais de Matemática para a disruptividade e eficiência que a computação evolucionária tem fornecido.

Após terem sido introduzidos os conceitos que permeiam os modelos de propagação não-linear, abordou-se a influência que as imperfeições de camada física podem adicionar aos cenários de transmissão óptica mais recorrentes. Como meio de suavizar estes impactos indesejáveis, mostrou-se a vantagem que o manuseio inteligente de potência de lançamento pode trazer. Para tal, apresentou-se um método evolucionário (PSO) que se comporta apropriadamente na otimização de variáveis contínuas e que mostrou eficiência e acurácia na maximização da razão sinal ruído sob regime não-linear. No entanto, sabendo que se limitar ao manuseio único de potência restringe a liberdade de gerência de recursos, partiu-se para um segundo tratamento evolucionário (Algoritmos Genéticos) que lida mais adequadamente com a discretização do espectro e torna-o fruto de otimização. Neste segundo momento avaliou-se, sob a ótica de relações de compromisso, a otimização multiobjetiva de requisitos que diagnosticam a viabilidade de transmissão, como: mínima margem de OSNR, soma das margens e banda ocupada. A resposta da técnica mostrou maior flexibilidade às encontradas na literatura (MILP, MINLP) quando o foco é pluralidade dos objetivos analisados.

Por fim, propôs-se uma alteração na técnica de otimização evolucionária (NSGA-II) como meio de garantir que a reorganização espectral das demandas de tráfego não fosse negligenciada. Esta última implementação permitiu que a exploração do espaço de buscas se tornasse mais eficaz e que a pluralidade de resultados garantisse maior grau de liberdade de escolhas de planejamento. Assim, ficaram evidenciadas características que constroem perfis de organização de potência e de espectro que precisam ser levadas em consideração na mitigação de ruído não-linear.

### 5.1 Trabalhos futuros

Inúmeras oportunidades de estudo foram descobertas neste trabalho e merecem atenção quando investigadas futuramente, são elas:

- desenvolver método evolucionário híbrido ressaltando as características do PSO e do GA,
- criar heurísticas cientes do comportamento não-linear de canais ópticos a partir dos resultados obtidos neste trabalho,

- testar em redes ópticas de tráfego dinâmico (o estático) e com topologia mais complexa os resultados de planejamento oriundos do padrão encontrado nos perfis discutidos aqui,
- otimizar o código desenvolvido em Java para o algoritmo utilizado pelas otimizações evolucionárias,
- efetivamente testar as formulações matemáticas tradicionais (MILP, MINLP) em cenários adicionais para checar a complexidade computacional quando comparada com a alternativa evolucionária.

## 5.2 Trabalhos publicados

Como fruto direto deste trabalho e de contribuições paralelas, quatro artigos contendo as discussões aqui levantadas foram publicados em duas conferências no ano de 2018, todos com co-autoria do prof. Dr. Raul Almeida Júnior, são eles:

- artigo apresentado no XXXVI Simpósio Brasileiro de Telecomunicações e processamento de sinais, em 2018, intitulado: Uma Análise Sobre Perfis Parabólicos de Lançamento de Potência para Canais Ópticos Elásticos Submetidos a Penalidades Não-Lineares de Camada Física,
- artigo apresentado no XXXVI Simpósio Brasileiro de Telecomunicações e processamento de sinais, em 2018, intitulado: Adaptação de Heurísticas para Redes Ópticas Elásticas Considerando os Efeitos da Camada Física,
- artigo apresentado no SBFoton International Optics and Photonics Conference, em 2018, intitulado: An Evolutionary Method to Optimize OSNR Margin in Elastic Optical Channels Subject to Non-Linear Physical Impairments,
- artigo apresentado no SBFoton International Optics and Photonics Conference, em 2018, intitulado: A Proposed BSR Heuristic Considering Physical Layer Awareness.

Uma observação para o trabalho de título: An Evolutionary Method to Optimize OSNR Margin in Elastic Optical Channels Subject to Non-Linear Physical Impairments. Este artigo foi considerado o quarto melhor trabalho entre todos os apresentados por estudantes da conferência e assim premiado com um reconhecimento da Sociedade Brasileira de Óptica e Fotônica.

## REFERÊNCIAS

- AGRAWAL, P. *Fiber-Optic Communications Systems*. [S.l.]: Wiley, 2002. Citado 2 vezes nas páginas 19 e 20.
- BONAMI, L. T. B. P. et al. An algorithmic framework for convex mixed integer nonlinear programs. *Discrete Optimization*, v. 5, n. 2, p. 186 – 204, maio 2018. Citado na página 52.
- BONAMI, P.; KILINC, M.; LINDEROTH, J. *Algorithms and software for convex mixed integer nonlinear programs*. [S.l.]: Springer, 2012. Citado na página 52.
- CARENA, A. et al. Modeling of the impact of nonlinear propagation effects in uncompensated optical coherent transmission links. *IEEE Journal of Lightwave Technology*, IEEE, v. 30, n. 10, p. 1524 – 1539, maio 2012. Citado na página 34.
- CHAVES, D.; PEREIRA, H.; MARTINS, C. B.-F. . J. A simulator for transparent optical networks. *Journal of Communication and Information Systems*, IEEE, v. 25, n. 1, jun 2010. Citado na página 17.
- DONG, C.; CHEN, Z.; SUN, S. The acceleration coefficients self-adapting in pso. *International Journal of Digital Content Technology and its Application*, v. 7, n. 5, mar 2013. Citado na página 31.
- HAUPT. *Practical Genetic Algorithms*. [S.l.]: Wiley- Interscience, 1998. Citado na página 42.
- HEPPNER, G. *The Ubiquity of Chaos*. [S.l.]: AAAS Publications, 1990. Citado na página 28.
- IRUKULAPATI, N. et al. Stochastic digital backpropagation. *IEEE Transactions on Communications*, IEEE, v. 62, n. 11, p. 3956 – 3968, nov 2014. Citado na página 34.
- IVES, D.; BAYVEL, P.; SAVORY. Adapting transmitter power and modulation format to improve optical network performance utilizing the gaussian noise model of nonlinear impairments. *Journal of Lightwave Technology*, IEEE, v. 32, n. 21, p. 4087 – 4096, nov 2014. Citado na página 33.
- IVES, D.; SAVORY, S. Transmitter optimized optical networks. *2013 Optical Fiber Communication Conference.*, IEEE, mar 2013. Citado 5 vezes nas páginas 33, 34, 39, 61 e 65.
- JINNO, M. et al. Introducing elasticity and adaptation into the optical domain toward more efficient and scalable optical transport networks. *2010 ITU-T Kaleidoscope: Beyond the Internet? - Innovations for Future Networks and Services*, IEEE, dez 2010. Citado na página 26.
- JOHANNISSON, P.; AGRELL, E. Modeling of nonlinear signal distortion in fiber-optic networks. *IEEE Journal of Lightwave Technology*, IEEE, v. 32, n. 23, p. 4544 – 4552, dez 2014. Citado 4 vezes nas páginas 22, 24, 34 e 52.
- J.ZHAO; H.WYMEERSCH; E.AGRELL. Nonlinear impairment aware resource allocation in elastic optical networks. *Optical Fiber Communication Conferenceoi*, IEEE, jun 2015. Citado 2 vezes nas páginas 15 e 50.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *Neural Networks, 1995. Proceedings.*, IEEE, v. 4, dez 1995. Citado 4 vezes nas páginas 28, 30, 31 e 70.

KLEKAMP, A.; DISCHLER, R.; BUCHALI, F. Limits of spectral efficiency and transmission reach of optical-ofdm super-channels for adaptive networks. *IEEE Photonics Technology Letters*, IEEE, v. 23, n. 20, p. 1526–1528, jul 2011. Citado na página 15.

MECOZZI, A.; IANNONE, E.; MATERA, M. S. F. *Nonlinear Communication Networks*. [S.l.]: Wiley, 1998. Citado na página 20.

MITCHEL, M. *An Introduction to Genetic Algorithms*. [S.l.]: MIT Press, 1996. Citado 2 vezes nas páginas 41 e 46.

NAKASHIMA, H. et al. Launch power optimization co-operated with digital nonlinear compensator for elastic optical network. *Proc. Opto-Electron. Commun. Conf.*, IEEE, p. 1–3, jun 2015. Citado 3 vezes nas páginas 15, 34 e 56.

PALKOPOULOU, E. et al. Nyquist-wdm-based flexible optical networks: Exploring physical layer design parameters. *Journal of Lightwave Technology*, IEEE, v. 31, n. 14, p. 2332–2339, jul 2013. Citado 2 vezes nas páginas 15 e 50.

PAVEL, L. Osnr optimization in optical networks: modeling and distributed algorithms via a central cost approach. *IEEE Journal on Selected Areas in Communications*, IEEE, v. 24, n. 4, p. 54 – 65, abr 2006. Citado na página 33.

POGGIOLINI, P. et al. The gn-model of fiber non-linear propagation and its applications. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 32, n. 4, p. 694–721, fev 2014. Citado 5 vezes nas páginas 15, 22, 23, 24 e 34.

REYNOLDS, C. Flocks, herds, and schools: A distributed behavioral model. *ACM SIGGRAPH'87 Proceedings*, Computer Graphics, jul 1987. Citado na página 28.

SIMON. *Evolutionary Optimization Algorithms: Biologically-Inspired and Population-Based Approaches to Computer Intelligence*. [S.l.]: Wiley, 2013. Citado na página 41.

SPLETT, A.; KURZKE, C.; PETERMANN, K. Ultimate transmission capacity of amplified optical fiber communication systems taking into account fiber nonlinearities. *Proc. Eur. Conf. Opt. Commun*, v. 2, p. 4144, fev 1993. Citado na página 14.

V.JADOUN et al. Stochastic digital backpropagation. *International Transactions on Electrical Energy*, v. 25, n. 4, p. 3060 – 3074, nov 2014. Citado na página 31.

YAN, L. et al. Resource allocation for flexible-grid optical networks with nonlinear channel model [invited]. *IEEE/OSA Journal of Optical Communications and Networking*, IEEE, v. 7, n. 11, p. B101–B108, nov 2015. Citado 11 vezes nas páginas 15, 26, 50, 51, 52, 53, 57, 58, 59, 60 e 65.

ZITZLER, E. *Evolutionary algorithms for multiobjective optimization: Methods and applications*. [S.l.: s.n.], 1999. Citado 2 vezes nas páginas 48 e 49.

## APÊNDICE A – UM EXEMPLO DE APLICAÇÃO DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

Uma visualização prática da técnica discutida é exposta a seguir. Para tal, é construído um cenário em que há o interesse em achar o máximo global da função:

$$f(x, y) = e^{-5(x^2+y^2)} + 2e^{-15(x^2+y^2-2(x+y)+2)} \quad (\text{A.1})$$

O espaço de busca de soluções está compreendido no plano:  $\{x, y \in \mathbb{R}^2 : -1 \leq x \leq 1.5 \cap -1 \leq y \leq 1.5\}$ .

A função que se deseja maximizar pode ser reescrita de forma a facilitar a compreensão do problema. Assim sendo, percebe-se que  $f(x, y)$  nada mais é do que a composição de duas superfícies de natureza gaussiana, uma centrada na origem  $(0, 0)$  e outra em  $(1, 1)$ , como exposto a seguir:

$$f(x, y) = \underbrace{e^{-5(x^2+y^2)}}_{\text{superfície 1}} + \underbrace{2e^{-15[(x-1)^2+(y-1)^2]}}_{\text{superfície 2}}. \quad (\text{A.2})$$

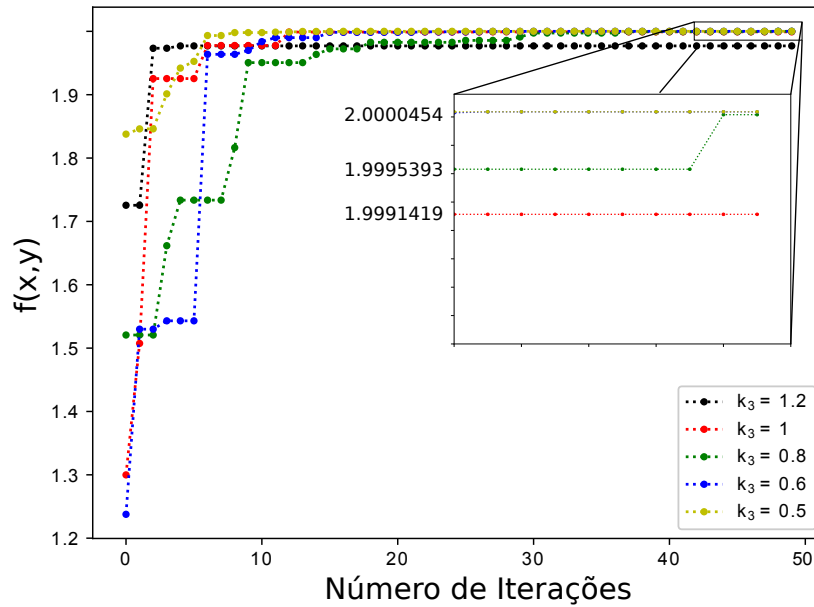
Como a superfície 2 possui amplitude duas vezes maior do que a primeira e os pontos de ótimo destas estão moderadamente apartados (tomando-se a distância euclidiana), não é difícil perceber que o máximo global de  $f(x, y)$  coincide com o ponto de máximo global da superfície 2, isto é,  $(1, 1)$ . Assim, usando estes artifícios matemáticos, é possível estimar o ponto geométrico para o qual as partículas devem convergir. O desafio é checar se o algoritmo também retorna o ponto  $(1,1)$  como solução.

Para caracterizar a população, foi escolhida uma contigência de 50 indivíduos. Resta agora suprir a necessidade de parametrização dos escalares cognitivo ( $k_1$ ), social ( $k_2$ ) e coeficiente de inércia ( $k_3$ ). Como foi sugerido em (KENNEDY; EBERHART, 1995), utilizou-se  $k_1 = k_2 = 2$ . No entanto, para  $k_3$  foi realizada uma análise de velocidade de convergência com alguns possíveis candidatos com o intuito de checar otimizações para valores diferentes do padrão ( $k_3 = 1$ ). Assim, para  $k_3$  usaram-se os valores na Fig. ?? buscando avaliar  $f(x, y)$  da melhor posição global ( $\zeta_{GBest}$ ).

As curvas da Fig. ?? expõem alguns comportamentos que merecem comentários. Como é possível identificar, à medida que o coeficiente  $k_3$  cresce, o comprimento do saltos, em direção ao valor de convergência, decresce. Estes saltos mais curtos permitem maior precisão e fazem com que  $k_3 = 0,5$  seja um candidato satisfatório, quando a proximidade com o valor real ( $f(1, 1) = 2,0000453$ ) é levada em consideração para apenas 50 iterações. Como constatado, a otimização alcançou um valor satisfatoriamente próximo (2,0000454), o que serviu para a tomada de decisão do parâmetro  $k_3$  a ser utilizado.

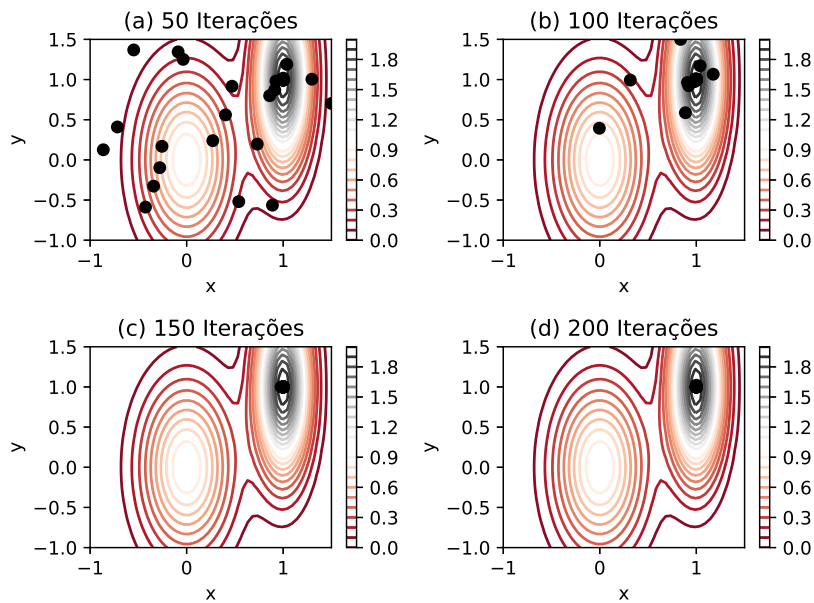
Olhando para a Fig. ??, vê-se ainda um retrato dos movimentos migracionais das 50 partículas em momentos cronológicos distintos (passos de 50 iterações). O mapa de contorno representa a expressão da Eq.A.2. É visível que o método está em concordância com o previsto no que diz respeito ao ponto de convergência das partículas.

**Figura 33** – Comportamento de convergência para diferentes valores de coeficiente de inércia assumindo-se um número fixo de 50 iterações.



Fonte: o autor.

**Figura 34** – Evolução migracional ( $k_1 = k_2 = 2$  e  $k_3 = 0,5$ ) das 50 partículas com passos de 50 iterações.



Fonte: o autor.



## APÊNDICE B – APLICANDO O ALGORITMO GENÉTICO

Seguindo o mesmo raciocínio delineado com o método de otimização por enxame de partículas, nesta seção será trabalhada a abordagem do mesmo exemplo, tratado anteriormente, a partir do GA. Na circunstância anterior, mostrou-se a partir de artifícios matemáticos, que o máximo global da função descrita em A.1 ocorre no ponto (1,1), o que foi mais adiante confirmado pelo uso da meta-heurística. Para exercitar os conceitos sobre o GA introduzidos recentemente, toma-se a mesma tratativa em busca desta solução.

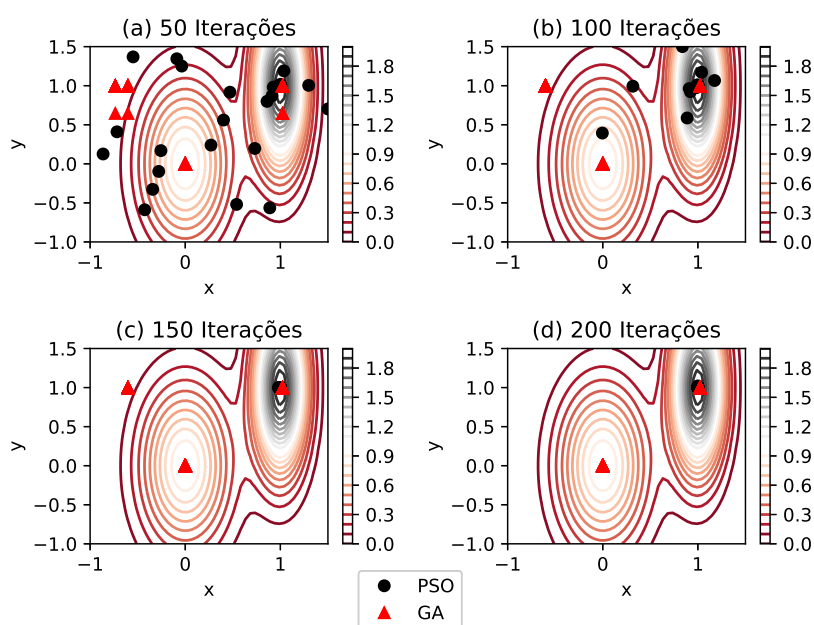
Adequando o referido exemplo ao novo contexto, é possível concluir que cada indivíduo é composto por apenas dois genes:  $x, y \in \mathbb{R}$ , que obviamente identificam uma coordenada cartesiana (x,y). Assim, o processo de cruzamento de dois cromossomos  $\zeta_{A1} = (x_1, y_1)$  e  $\zeta_{A2} = (x_2, y_2)$  origina os outros dois indivíduos  $\zeta_{D1} = (x_1, y_2)$  e  $\zeta_{D2} = (x_2, y_1)$ . A mutação neste caso dar-se-á via escolha aleatória do valor do gene, a qual é uniformemente distribuída dentro de um intervalo, que neste caso é entre [-1, 1.5] para  $x$  e  $y$ . A seleção é feita obedecendo o critério de maximização, ou seja, os valores de função objetivo mais elevados atraem os indivíduos sobreviventes. Assim, antes de partir direto para os resultados obtidos, é preciso descrever um pouco mais sobre dois parâmetros que compõem a meta-heurística.

- **Probabilidade de Cruzamento ( $Pr_C$ ):** É a probabilidade de uma dupla de indivíduos ascendentes propriamente realizar a troca de material genético. No exemplo a seguir assumiu-se igual a 100%, isto é, a cada iteração, N partículas ascendentes geram N descendentes. A escolha deste valor é simplesmente para dar mais celeridade ao processo de iteração e, conseqüentemente, percorrer o espaço de buscas em menos tempo.
- **Probabilidade de Mutação ( $Pr_M$ ):** É a probabilidade de um gene pertencente a um indivíduo ter seu valor alterado. Considerou-se um valor de 40% para esta variável.

Para uma análise comparativa justa com o uso do PSO, decidiu-se usar o mesmo número de indivíduos (50) do exemplo anterior. A Fig. ?? mostra com clareza os status dos indivíduos a 50, 100, 150 e 200 iterações. Não há dúvidas de que a solução encontrada pelo GA graficamente está em concordância com aquela determinada pelo PSO, já que, no último cenário (200 iterações), há indivíduos que claramente localizam-se próximos ao ponto (1,1), como esperado. Alguns comentários devem ser mencionados, contudo.

O primeiro diz respeito à sensibilidade a ótimos locais. Como é sabido, a função descrita pela Equação A.1 possui um máximo local em (0,0). Pela evolução das migrações, é possível perceber que no GA algumas soluções persistem neste ponto (200 iterações), enquanto todas as soluções no PSO convergem para as vizinhanças do máximo global (1,1). Este fato está atrelado à inteligência dos deslocamentos migracionais de cada método, isto é, o PSO possui uma dinâmica que leva em conta regras matemáticas associadas à aleatoriedade para aproximação ao ponto

**Figura 35** – Processo de procura de máximo global de superfície quando GA é contrastado com PSO. Foram utilizados 50 indivíduos com  $Pr_C = 100\%$  e  $Pr_M = 40\%$ .



Fonte: o autor.

de máximo. Já o GA depende da total aleatoriedade do processo de mutação, o qual desacelera um pouco mais a convergência pois não há uma inteligência que direcione os movimentos. Além disso, máximos locais tendem a ser inseridos na etapa de elitismo e, assim, persiste a sobrevivência de características próprias deste ponto.

O segundo fato é quanto à acurácia das soluções. Relembrando, o PSO consegue determinar o valor do máximo (2,0000454) com desvio de  $5 \times 10^{-6}\%$  em comparação ao valor real com apenas 50 iterações, diferentemente do GA, que ainda com 200 iterações retorna como máximo global um valor (1,983033) com 0,85% de desvio do esperado.

É razoável perguntar: dado que o PSO, no problema apresentado, mostrou maior acurácia e precisão em comparação ao GA para um determinado número de iterações, por que não permanecer com ele como solução definitiva? A resposta é simples e vem sendo reiterada ao longo deste trabalho, o GA consegue operar melhor a discretização do espectro óptico, assim, suprimindo uma deficiência que acarretaria em alterações complexas e ineficientes do PSO para atender esta demanda. Antes de partir para a aplicação do GA nas simulações numéricas de transmissão óptica, é necessária a explanação do tipo de Algoritmo Genético que foi utilizado neste trabalho, o NSGA-II.