



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

MATHEUS LÔBO DOS SANTOS

**Abordagens para Atribuição de Espectro em Redes Ópticas Elásticas Baseadas em
Perda de Capacidade Sob Múltiplas Rotas**

Recife

2021

MATHEUS LÔBO DOS SANTOS

**Abordagens para Atribuição de Espectro em Redes Ópticas Elásticas Baseadas em
Perda de Capacidade Sob Múltiplas Rotas**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Comunicações.

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

Coorientador: Prof^o. Dr. Danilo Ricardo Barbosa de Araújo

Recife

2021

Catálogo na fonte:
Bibliotecário Carlos Moura, CRB-4 / 1502

S237a Santos, Matheus Lôbo dos.
Abordagens para atribuição de espectro em redes ópticas elásticas baseadas em perda de capacidade sob múltiplas rotas. / Matheus Lôbo dos Santos. – 2021.
73 f.: il.

Orientador: Prof. Dr. Raul Camelo de Andrade Almeida Júnior.
Coorientador: Prof. Dr. Danilo Ricardo Barbosa de Araújo.
Dissertação (mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2021.
Inclui referências e apêndice.

1. Engenharia elétrica. 2. Redes ópticas elásticas. 3. Alocação do espectro.
4. MSCL. 5. NSGAI. I. Almeida Júnior, Raul Camelo de Andrade (orientador).
II. Araújo, Danilo Ricardo Barbosa de (coorientador). III. Título.

621.3 (22. ed.)

UFPE
BCTG/2022-173

MATHEUS LÔBO DOS SANTOS

Abordagens para Atribuição de Espectro em Redes Ópticas Elásticas Baseadas em Perda de Capacidade Sob Múltiplas Rotas

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Comunicações.

Aprovada em: 10/12/2021.

BANCA EXAMINADORA

Prof^o. Dr. Raul Camelo de Andrade Almeida Júnior (Orientador)
Universidade Federal de Pernambuco — UFPE

Prof^o. Dr. Danilo Ricardo Barbosa de Araújo (Examinador Externo)
Universidade Federal Rural de Pernambuco — UFRPE

Prof^o. Dr. André Victor Silva Xavier (Examinador Externo)
Universidade Federal de Pernambuco — UFPE

Prof^o. Dr. Alex Ferreira dos Santos (Examinador Externo)
Universidade Federal do Recôncavo da Bahia — UFRB

AGRADECIMENTOS

Agradeço primeiramente a meus pais Maria Belanizia e Juvenal Gonçalves por serem meu espelho de vida e pelo apoio incondicional em minhas decisões. O carinho e a educação que vocês me proporcionaram formaram o homem que sou hoje.

Agradeço a Dilma Gonçalves por todos os conselhos e assistência durante o período que passei focado neste trabalho.

Agradeço a Millena Lôbo por toda a ajuda com esse trabalho, me guiando a dar o melhor de mim sempre.

Agradeço a Laryssa Silva por todo incentivo e companheirismo, me aturando durante estes anos de pesquisas e me trazendo felicidades nos momentos de desânimo e dificuldades.

Agradeço ao amigo Rodrigo Fontan por todo suporte, motivação e períodos de descontração ao longo dessa jornada de desafios.

Agradeço ao professor Dr. Raul Camelo, meu orientador, pelos ensinamentos e conhecimentos transmitidos ao longo desses anos, sempre com muita dedicação e compreensão. A sua grande competência acadêmica sempre será um norte para mim.

Agradeço ao professor Dr. Danilo Araújo, meu coorientador, pela orientação com sugestões e críticas pontuais ao longo dessa pesquisa.

Agradeço a todos os amigos que me acompanharam ao longo desses anos, em especial a Andy, Higor, João, Maria e Sérgio a quem tive a honra de conhecer e trocar conhecimentos ao longo das disciplinas.

Agradeço aos professores do programa pelo conhecimento transmitido neste Mestrado.

Agradeço a todos os membros da banca por aceitarem o convite para participar e por ajudar a enriquecê-la com suas críticas.

Agradeço ao CNPq pelo suporte financeiro através da bolsa de Mestrado.

Agradeço a secretaria e coordenação do PPGEE por toda assistência prestada e pela oportunidade de entrar no programa.

Agradeço a todos que contribuíram significativamente para esse trabalho. Obrigado!

“O método científico é comprovado e verdadeiro. Não é perfeito, é apenas o melhor que temos. Abandoná-lo, junto com seus protocolos céticos, é o caminho para uma idade das trevas.” (SAGAN, [19–] apud ATA; PERKS, 2016, p. 103).

RESUMO

Esta Dissertação discute soluções para o problema de roteamento e alocação de espectro em redes ópticas elásticas. As propostas apresentadas são uma adaptação do algoritmo de atribuição de espectro denominado *Min Slot-Continuity Capacity Loss* (MSCL). Esse algoritmo reduz o impacto da rede ao escolher um conjunto de *slots* que apresenta a menor perda de capacidade. Ambas as propostas recorrem a um conjunto de múltiplas rotas obtido pelo algoritmo de roteamento Yen-MH, cujo as rotas são selecionadas a partir do menor número de enlaces. As heurísticas são denominadas MSCL Sequencial e MSCL Combinado, definidas pela maneira como elas escolhem a solução dentre as de menor perda de capacidade nas rotas. Os desempenhos das heurísticas MSCL foram comparados com a heurística amplamente utilizada na literatura chamada *First-Fit*, heurística esta que requer baixo esforço computacional e apresenta bons resultados. Os resultados mostram a capacidade das heurísticas MSCL em reduzir a probabilidade de bloqueio, seguindo o seguinte ordenamento por desempenho: *First-Fit*, MSCL Sequencial e MSCL Combinado. No entanto, o algoritmo MSCL demanda alto esforço computacional, portanto, procedimentos de otimização foram abordados com o objetivo de melhorar o tempo de simulação das heurísticas, mantendo o compromisso com a probabilidade de bloqueio. As otimizações utilizam heurísticas executadas de forma estática (ou seja, com ordenamento pré-configurado) e dinâmicas (com ordenamento modificado durante a operação da rede). Um algoritmo genético inspirado no NSGAI foi desenvolvido para encontrar soluções mais genéricas e de bom desempenho no espaço de probabilidade de bloqueio e tempo de simulação. As heurísticas foram comparadas com o MSCL padrão, sendo encontradas melhorias para a probabilidade de bloqueio e o tempo de simulação. Os resultados mostram os benefícios dos métodos de otimização, demonstrando as suas eficácias.

Palavras-chaves: redes ópticas elásticas; alocação do espectro; MSCL; NSGAI.

ABSTRACT

This Dissertation discusses solutions to the problem of routing and spectrum allocation in elastic optical networks. The presented proposals are an adaptation of the spectrum allocation algorithm known as Min Slot-Continuity Capacity Loss (MSCL). This algorithm reduces the impact on the network capacity by choosing a set of slots that provides the minimum loss of capacity. Both proposals use a set of multiple routes obtained by the Yen-MH routing algorithm, which routes are selected based on the smallest number of links. The heuristics are called MSCL *Sequencial* and MSCL *Combinado*, relating how they choose the solution among those with the lowest loss of capacity on the routes. MSCL *Sequencial* and MSCL *Combinado* were compared with the widely used heuristic in the literature referred to as First-Fit, which requires low computational effort and presents good results. The results show the capacity of the MSCL heuristics to reduce the blocking probability, presenting the following order in performance: First-Fit, MSCL *Sequencial* and MSCL *Combinado*. However, the MSCL algorithm demands high computational effort, therefore, optimization procedures were applied to mitigate the simulation time of the heuristics, keeping the commitment with the blocking probability. Optimizations use static heuristics (i.e., those with pre-configured ordering) and dynamic ones (i.e., those with ordering modified during network operation). A genetic algorithm based on NSGAI1 was developed to find more generic and well-performing solutions in the space of blocking probability and simulation time. The heuristics were compared with the standard MSCL and improvements on blocking probability and simulation time were found. The results show the benefits of the optimization methods, demonstrating the effectiveness of their use.

Keywords: elastic optical networks; spectrum allocation; MSCL; NSGAI1.

LISTA DE FIGURAS

Figura 1 – Previsão elaborada pelo Cisco do número de usuários para os anos de 2018 a 2023.	17
Figura 2 – Conceito de grade de tamanho fixo (WDM) e grade de tamanho flexível (EONs).	21
Figura 3 – Duas possíveis rotas para estabelecer conexão entre os nós 1 e 3.	22
Figura 4 – Exemplo de restrição de continuidade de espectro para a rota $1 \mapsto 5 \mapsto 4 \mapsto 3$	23
Figura 5 – Exemplo de fragmentação do espectro no vetor de disponibilidade de uma rota.	24
Figura 6 – Exemplo de rotas interferentes.	27
Figura 7 – Fluxograma da heurística <i>First-Fit</i>	28
Figura 8 – Fluxograma da heurística MSCL.	29
Figura 9 – Representação das possibilidades de alocação para uma requisição de 2 <i>slots</i> no vetor de disponibilidade.	30
Figura 10 – Fluxograma para a heurística MSCL Sequencial.	32
Figura 11 – Fluxograma para a heurística MSCL Combinado.	33
Figura 12 – Exemplo de alocação das heurísticas abordas nesta dissertação.	34
Figura 13 – Representação das topologias: (a) Finlândia com 12 nós, (b) NSFNet com 14 nós, (c) Abilene com 11 nós e (d) USANet com 24 nós.	36
Figura 14 – Número de rotas interferentes encontradas por enlace para a topologia Finlândia.	37
Figura 15 – Topologia NSFNet: (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir da menor ocupação WDM.	38
Figura 16 – Topologia Finlândia: (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir da menor ocupação WDM.	39

Figura 17 – Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir do menor número de enlaces; (a) Topologia Abilene; (b) Topologia USANet.	40
Figura 18 – Comparativo entre os tempos de simulação para as heurísticas apresentadas. (a) Topologia NSFNet; (b) Topologia Finlândia.	41
Figura 19 – Visualização da alocação do espectro entre as heurísticas MSCL e First-Fit.	42
Figura 20 – Topologia Finlândia usando camada física: (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede para K rotas ordenadas a partir da menor ocupação WDM.	44
Figura 21 – (a) Distribuição do tempo de simulação após 100 repetições. (b) Ciclos MSCL em função do tempo de simulação, conforme variação do número de <i>slots</i> de frequência.	46
Figura 22 – Exemplos das nomenclaturas das heurísticas de ordenação. Exemplo de custo pela métrica de ocupação.	47
Figura 23 – Exemplo de soluções do problema MSCL em uma frente de Pareto.	48
Figura 24 – Exemplo dos conjuntos predominantes e não-predominantes.	48
Figura 25 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 1$ à carga de 200 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.	49
Figura 26 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 2$ à carga de 270 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.	50
Figura 27 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 3$ à carga de 280 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.	51
Figura 28 – Representação do indivíduo para a heurística de otimização multi-objetivo.	54
Figura 29 – Exemplo de cruzamento do tipo 1 para a representação do cromossomo utilizado.	56
Figura 30 – Exemplo de cruzamento do tipo 2 para a representação do cromossomo utilizado.	57
Figura 31 – Exemplo de mutação para a representação do cromossomo utilizado.	57

Figura 32 – Fluxograma do funcionamento do algoritmo genético.	58
Figura 33 – Frentes de Pareto para o algoritmo genético. População inicial de indivíduos. (a) Topologia NSFNet. (b) Topologia Finlândia.	60
Figura 34 – Frentes de Pareto para o algoritmo genético. População de indivíduos após 50 gerações com cruzamento do tipo 1. (a) Topologia NSFNet. (b) Topo- logia Finlândia.	61
Figura 35 – Frentes de Pareto para o algoritmo genético com cruzamento do tipo 1. População de indivíduos após 500 gerações. (a) Topologia NSFNet. (b) Topologia Finlândia.	62
Figura 36 – Frentes de Pareto para o algoritmo genético com cruzamento do tipo 2. População de indivíduos após 500 gerações. (a) Topologia NSFNet. (b) Topologia Finlândia.	63
Figura 37 – Topologia NSFNet em $k = 1$. (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede. (b) Comparativo entre o tempo de simulação <i>versus</i> carga da rede.	64
Figura 38 – Topologia Finlândia em $k = 1$. (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede. (b) Comparativo entre o tempo de simulação <i>versus</i> carga da rede.	65
Figura 39 – Topologia NSFNet em $k = 2$. (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede. (b) Comparativo entre o tempo de simulação <i>versus</i> carga da rede.	66
Figura 40 – Topologia Finlândia em $k = 2$. (a) Comparativo entre a probabilidade de bloqueio <i>versus</i> carga da rede. (b) Comparativo entre o tempo de simulação <i>versus</i> carga da rede.	66

LISTA DE TABELAS

Tabela 1 – Parâmetros de configuração do simulador.	34
Tabela 2 – Parâmetros de configuração do simulador para utilização com camada física.	43
Tabela 3 – Parâmetros de configuração para o algoritmo genético.	59
Tabela 4 – Parâmetros de configuração do simulador para o algoritmo genético.	60

LISTA DE ABREVIATURAS E SIGLAS

ASE	<i>Amplified Spontaneous Emission</i>
BSR	<i>Best Among the Shortest Routes</i>
CAGR	<i>Compound Annual Growth Rate</i>
CD	<i>Crowding Distance</i>
EON	<i>Elastic Optical Network</i>
FF	<i>First-Fit</i>
GA	<i>Genetic Algorithm</i>
ITU-T	<i>International Telecommunication Union - Telecommunication</i>
MH	<i>Minimum Hop</i>
MSCL	<i>Min Slot-Continuity Capacity Loss</i>
NP	<i>Non-deterministic Polynomial-time</i>
NSGAI	<i>Non-dominated Sorting Genetic Algorithm II</i>
O-D	<i>Origem-Destino</i>
OEO	<i>Optical-Electronic-Optical</i>
PSO	<i>Particle Swarm Optimization</i>
PSR	<i>Power Series Routing</i>
RSA	<i>Routing and Spectrum Assignment</i>
RWA	<i>Routing and Wavelength Assignment</i>
SP	<i>Shortest Path</i>
WDM	<i>Wavelength Division Multiplexing</i>

LISTA DE SÍMBOLOS

P_b	Probabilidade de bloqueio
R_b	Quantidade de requisições bloqueadas
R_e	Quantidade de requisições enviadas
K	Número de rotas buscadas para cada par origem-destino
R	Conjunto de rotas para um par origem-destino. A quantidade de elementos em R é igual a K
r	Rota que interliga caminhos em uma topologia
N	Conjunto de todas as possíveis demandas que podem ser alocadas em r
n	Demanda de <i>slots</i> para uma requisição
s_f	Índice do último <i>slot</i> do espectro
s_i	Índice do primeiro à acomodar uma demanda
s_b	Índice do primeiro à acomodar uma demanda, para obter a menor perda de capacidade na rota r
C	Valor da menor perda de capacidade na rota r
$s(n)$	Número de formas possíveis para alocar uma demanda n
L	Conjunto de rotas as lacunas presentes no vetor de disponibilidade
h_l	Quantidade de disponíveis em uma lacuna
$s(h_l, n)$	Número de formas possíveis como uma demanda n pode ser alocada em uma lacuna de tamanho h_l
$C^{<r>}(n)$	Perda de capacidade para requisição com n <i>slots</i> após o estabelecimento na rota r
I_r	Conjunto de rotas interferentes a rota r
ψ	Representa o estado atual da rede

ψ'	Representa o estado da rede após o estabelecimento da requisição
$S^{<p>}(\psi, n)$	Número total de possibilidades de alocação que uma requisição por n slots tem para alocar no caminho p antes do estabelecimento de r
$S^{<p>}(\psi', n)$	Número total de possibilidades de alocação que uma requisição por n slots tem para alocar no caminho p após estabelecimento de r
$C^{<r>}$	Perda de capacidade total para todo o conjunto N
T_{node}	Número de nós presente em uma topologia
R_t	Número de rotas totais para uma topologia
P	Polarização
B	Taxa de <i>bits</i> da transmissão
B_{slot}	Taxa de <i>bits</i> para um <i>slot</i>
X	Constelação da modulação utilizada no cálculo da demanda
C_s	Tamanho do cromossomo (quantidade de genes)
P_i	População inicial dos indivíduos
Q_g	População auxiliar de indivíduos
$ X $	Representa o número de elementos em X
f_r	Fator aleatório uniforme entre 0 e 1
P_l	Probabilidade limiar para criação do indivíduo
P_c	Probabilidade de cruzamento
P_h	Probabilidade de herança
P_m	Probabilidade de mutação
I_m	Número máximo de vezes que um mesmo indivíduo pode ser re-simulado
E_g	Porcentagem de Elitismo dos melhores indivíduos
g_{max}	Número máximo de gerações para o algoritmo genético

N_l	Carga da rede em Erlangs usada no treinamento
t_s	Tempo de simulação de uma única simulação
t_f	Tempo de simulação total após g_{max} gerações
O_r	Quantidade de <i>slots</i> ocupados na rota r
V_r	Vetor de ocupação geral na rota r

SUMÁRIO

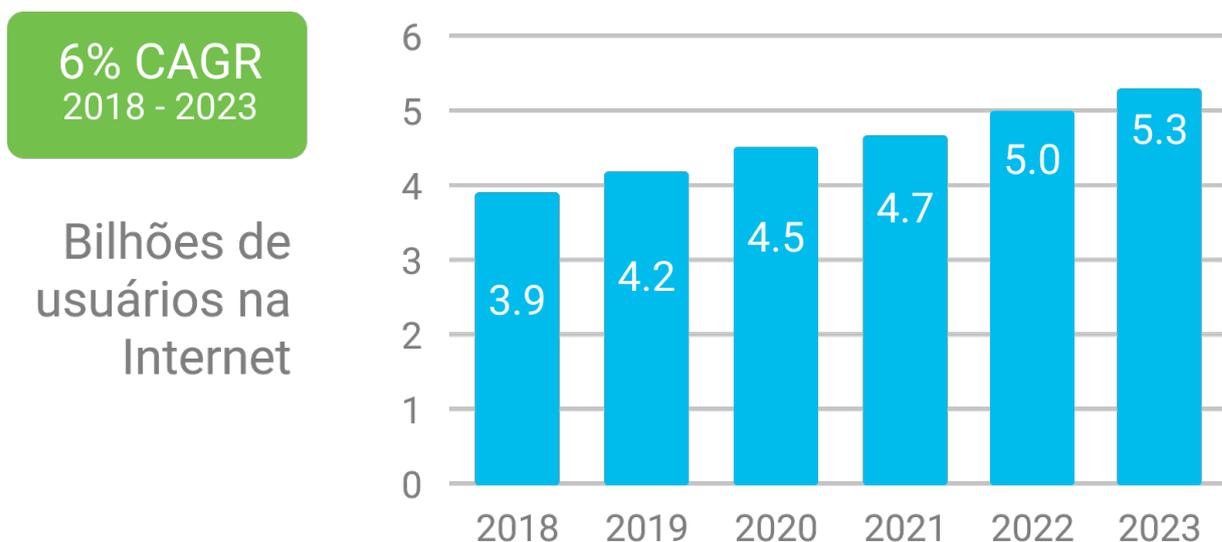
1	INTRODUÇÃO	17
1.1	ORGANIZAÇÃO DA DISSERTAÇÃO	18
2	REDES ÓPTICAS ELÁSTICAS	20
2.1	PROBLEMA RSA	23
2.1.1	Fragmentação do espectro	24
2.1.2	Roteamento	25
2.1.2.1	<i>Conjunto de rotas interferentes</i>	26
2.1.3	Alocação de espectro	27
2.1.3.1	<i>Algoritmo MSCL</i>	28
3	HEURÍSTICAS PROPOSTAS	31
3.1	MSCL SEQUENCIAL	31
3.2	MSCL COMBINADO	32
3.3	PROCEDIMENTO EXPERIMENTAL	34
3.4	RESULTADOS	36
3.4.1	Resultados com Camada Física	43
4	OTIMIZAÇÃO DAS HEURÍSTICAS	45
4.1	HEURÍSTICAS DE ORDENAÇÃO	46
4.2	ALGORITMOS EVOLUTIVOS	52
4.2.1	Otimização Multi-Objetiva	53
4.2.1.1	<i>Avaliação e Seleção dos Indivíduos</i>	55
4.2.1.2	<i>Cruzamento</i>	55
4.2.1.3	<i>Mutação</i>	56
4.2.1.4	<i>Estrutura do Algoritmo Genético Multi-Objetivo</i>	58
4.3	COMPARAÇÃO DOS RESULTADOS	59
5	CONCLUSÕES	67
5.1	PUBLICAÇÃO	68
5.2	TRABALHOS FUTUROS	68
	REFERÊNCIAS	69
	APÊNDICE A – VETOR DE OCUPAÇÃO GERAL	73

1 INTRODUÇÃO

Devido à pandemia causada pelo novo Coronavírus, e a necessidade de se manter em isolamento social, a demanda por Internet no tráfego residencial aumentou para suprir trabalho remoto, entretenimento, educação e comércio, acarretando mudanças no núcleo da Internet (FELDMANN et al., 2021). Com isso, pesquisas são necessárias para atingir as novas aplicações e tecnologias que exigem uma maior taxa de transmissão e confiabilidade. A utilização de redes ópticas visam suprir essas demandas de mercado, aplicando novas estratégias em busca de reduzir o custo financeiro da aplicação (ARAÚJO, 2015).

Segundo a Cisco (CISCO, 2020), o número de usuários conectados à Internet está projetado para crescer de 3,9 bilhões em 2018 para 5,3 bilhões em 2023 a uma taxa composta de crescimento anual (CAGR, do inglês *Compound Annual Growth Rate*) de 6%, conforme mostra a Figura 1. A alta demanda será intensificada com a chegada das redes 5G ao Brasil no ano de 2022. A infraestrutura de implementação dessa nova rede de comunicação móvel necessita de uma complexa rede de antenas espalhada pelas cidades. Essas antenas, no que lhe concerne, são alimentadas através de uma cobertura de fibra óptica, garantindo que as baixas latências e altas taxas da rede 5G sejam obtidas (NOOMIS, 2021).

Figura 1 – Previsão elaborada pelo Cisco do número de usuários para os anos de 2018 a 2023.



Fonte: Elaborado pelo Autor (2021). Adaptado de Cisco (2020).

Os problemas obtidos no projeto de uma rede óptica são computacionalmente custosos, sendo classificados como um problema NP-difícil. Essa classificação implica dizer que a solução ótima para o problema não pode ser obtida em tempo aceitável ao ser aplicado a grandes

cenários (KO et al., 1997). Sendo assim, heurísticas e meta-heurísticas são desenvolvidas e estudadas para encontrar uma solução ao problema. As heurísticas são, segundo o entendimento de Zanakis e Evans (1981), algoritmos que apresentam bons desempenhos ou soluções factíveis de modo fácil e rápido, mas não apresentam provas de serem sempre rápidas e eficientes em todos os problemas. Golbarg e Luna (2005) complementam essa definição destacando que as heurísticas conseguem encontrar boas soluções ou até mesmo a otimalidade da solução, especialmente ao iniciar a busca a partir de uma solução encontrada próxima do ótimo (SOBREIRO, 2012). Uma meta-heurística é uma forma genérica de resolver problemas de otimização usando um método heurístico, necessitando de poucas modificações pelo usuário. (FREITAS et al., 2009).

Essa dissertação apresenta um estudo acerca do problema de roteamento e atribuição do espectro em redes ópticas elásticas e, baseada nos desafios associados à implementação dessa tecnologia, propõe formas eficazes de solucionar estes problemas. Inicialmente, serão estudados a influência do conjunto de rotas interferentes e o problema de fragmentação do espectro, problema este que ocorre quando conexões com diversos tamanhos de demanda são estabelecidas e encerradas dinamicamente. Este processo acaba gerando pequenos fragmentos de espectro que, por não acomodarem o tamanho da demanda solicitada, acabam por não serem utilizados, causando a subutilização do espectro.

Para mitigar este problema, em Almeida-Jr. et al. (2013) os autores propuseram a heurística de alocação de espectro denominada Menor Perda de Capacidade para a Continuidade de *Slot* (MSCL, do inglês *Min Slot-Continuity Capacity Loss*). Esse algoritmo escolhe, no espectro de frequência de uma rota, aquele conjunto de *slots* que apresentará o menor impacto na rede. Essa dissertação usa como base o algoritmo MSCL, considerando um cenário de múltiplas rotas para um mesmo par origem-destino, para criar duas heurísticas cujo objetivo é evitar rotas que sejam mais suscetíveis a fragmentar o espectro. O MSCL é um algoritmo complexo computacionalmente, sendo assim, além da probabilidade de bloqueio, o tempo de execução será considerado para comparar os resultados obtidos. Além desses objetivos, serão propostas novas heurísticas cujo objetivo é reduzir a complexidade do algoritmo e manter o desempenho da probabilidade de bloqueio.

1.1 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está estruturada em cinco capítulos.

No Capítulo 2 será apresentada a revisão bibliográfica fundamental de redes ópticas, com ênfase em redes ópticas elásticas, para o pleno entendimento das heurísticas apresentadas nos próximos capítulos. São contextualizados as características, arquiteturas e funcionalidades dessa rede óptica. É feita uma revisão da literatura sobre os trabalhos relacionados com a alocação de espectro em redes ópticas elásticas.

No Capítulo 3 são apresentadas e descritas as duas propostas de alocação de espectro usando a heurística MSCL aplicada a um conjunto de múltiplas rotas. Inicialmente é apresentado a problemática do conjunto de rotas interferentes, e o impacto que esse problema proporciona ao ser considerado em um cenário de múltiplas rotas. Posteriormente é apresentada a primeira heurística, e mais simples, intitulada de MSCL Sequencial, descrevendo seu funcionamento. A segunda heurística, que introduz uma nova abordagem de escolha de rota é proposta em sequência, mostrando as diferenças para a primeira proposta e suas melhorias. É apresentado o ambiente de simulação e suas configurações, utilizando topologias utilizadas na literatura. Os resultados de comparação com a heurística *First-Fit* são mostrados na sequência mostrando, por fim, a fragmentação do espectro sendo reduzida pelas heurísticas propostas.

O início do Capítulo 4 apresenta uma nova métrica para mensurar o desempenho das heurísticas MSCL propostas no Capítulo 3, intitulado Ciclos MSCL. Considerando o compromisso entre os Ciclos MSCL e a probabilidade de bloqueio, são propostas novas heurísticas com objetivo de melhorar o desempenho das propostas estabelecidas no capítulo 3. No decorrer do capítulo é aplicado uma técnica de algoritmo evolucionário para comparar com as heurísticas apresentadas neste capítulo. Os resultados dessa comparação são apresentados na sequência, fazendo uma análise das diferenças obtidas.

Por último, no Capítulo 5 são apresentadas as conclusões finais desta dissertação, fazendo um resumo das contribuições realizadas neste trabalho, ressaltando as vantagens e desafios encontrados para obtenção dos resultados. Além disso, neste capítulo serão apresentadas as principais sugestões para continuidade desta pesquisa em trabalhos futuros.

2 REDES ÓPTICAS ELÁSTICAS

Uma rede óptica que recorre à tecnologia de multiplexação por comprimento de onda (WDM, do inglês *Wavelength Division Multiplexing*) foi o modelo de redes mais utilizado nas últimas décadas. Essa rede usa canais com uma faixa de espectro fixo para a transmissão de dados (RAMASWAMI; SIVARAJAN; SASAKI, 2009). As redes WDM são classificadas conforme a maneira que o sinal é recuperado, sendo classificadas em 3 categorias: opacas, transparentes e translúcidas. Uma rede óptica classificada como opaca indica que conversões óptico-eletrônico-óptico (OEO, do inglês *Optical-Electronic-Optical*) são realizadas para cada nó da rede. Converter o sinal óptico para elétrico necessita de equipamentos especializados que apresentam um custo elevado, conforme Fonseca (2005).

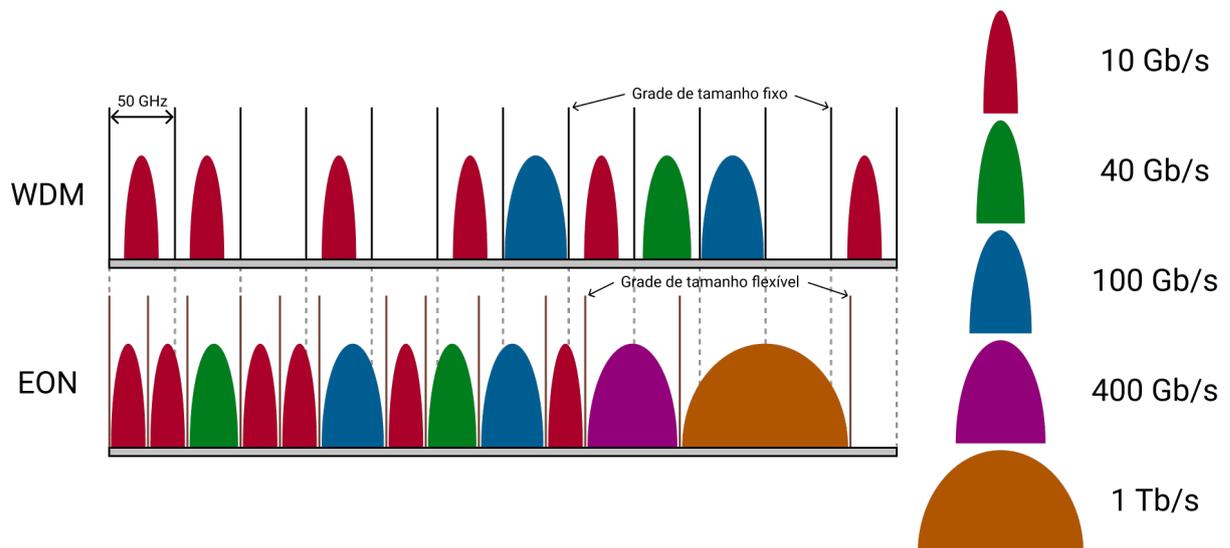
Em uma rede transparente, o sinal óptico do nó de origem chega ao nó destino utilizando somente o domínio óptico, sem realizar conversões OEO. Durante o percurso, o sinal pode ser amplificado sem conhecimento das informações que estão trafegando, garantindo a segurança das informações. Por fim, as redes classificadas como translúcidas possuem a capacidade de realizar a comutação do caminho tanto no domínio óptico quanto no eletrônico. Essa característica das redes translúcidas viabiliza que em rotas longas o sinal óptico seja regenerado eletronicamente em um ou mais de seus nós intermediários, visando restaurar a qualidade inicial do sinal, enquanto mantém a comutação óptica nos demais nós. Essa arquitetura consegue agregar a agilidade e redução de custos das redes transparentes e a qualidade do sinal óptico garantido pelas redes ópticas opacas através das conversões OEO (HOROTA, 2016).

Nas redes WDM, o processo de roteamento e alocação de comprimento de onda (RWA, do inglês *Routing and Wavelength Assignment*) é um ponto crítico por influenciar como os recursos serão usados na rede. O problema do RWA consiste em encontrar uma rota e um comprimento de onda para cada requisição de conexão. As redes WDM conseguem alcançar altas taxas de transmissão, entretanto, não fazem bom uso da banda espectral por canal WDM para cenários com serviços heterogêneos (XAVIER, 2016). Em Jinno et al. (2009) foi proposta uma nova arquitetura de rede flexível, chamada redes ópticas elásticas (EON, do inglês *Elastic Optical Network*). Essa rede surge como alternativa às redes WDM para atender efetivamente demandas heterogêneas. Em comparação ao WDM, as EONs utilizam a banda espectral eficientemente. Essa eficiência decorre da utilização de um ou mais *slots* de frequência consecutivos, minimizando os desperdícios na quantidade de banda necessária (XAVIER, 2016).

Nas redes EON, o problema de acomodação das demandas que chegam à rede é conhecido como roteamento e alocação de espectro (RSA, do inglês *Routing and Spectrum Assignment*).

A Figura 2 exemplifica a diferença entre os canais nas arquiteturas WDM (grade de tamanho fixo) e EON (grade de tamanho flexível). O espaçamento comumente utilizado na literatura para canais WDM é de 50 GHz, embora haja trabalhos que estudem a aplicação de outras faixas de frequência (NAKAMURA et al., 2018). Um canal de 50 GHz consegue acomodar uma taxa de transmissão de 100 Gb/s. Quando esses canais são usados para acomodar requisições com taxas inferiores, nota-se que há um desperdício dos recursos. Por outro lado, os canais com grades flexíveis, provenientes das EONs, oferecem uma melhor acomodação das demandas heterogêneas, o que provê um melhor uso da banda de espectro. Esse melhor aproveitamento é devido à divisão do espectro em pequenas porções de frequência de tamanho fixo denominadas *slot*, podendo-se utilizar mais de um em sequência. Esses *slots* têm uma capacidade de transmissão inferior à de uma grade nas redes WDM comuns. Segundo as especificações estabelecidas pelo ITU-T (ITU-T G.694.1, 2020), cada *slot* corresponde a 12,5 GHz de frequência, sendo o valor comumente adotado da literatura.

Figura 2 – Conceito de grade de tamanho fixo (WDM) e grade de tamanho flexível (EONs).



Fonte: Elaborado pelo Autor (2021). Adaptado de Gerstel et al. (2012).

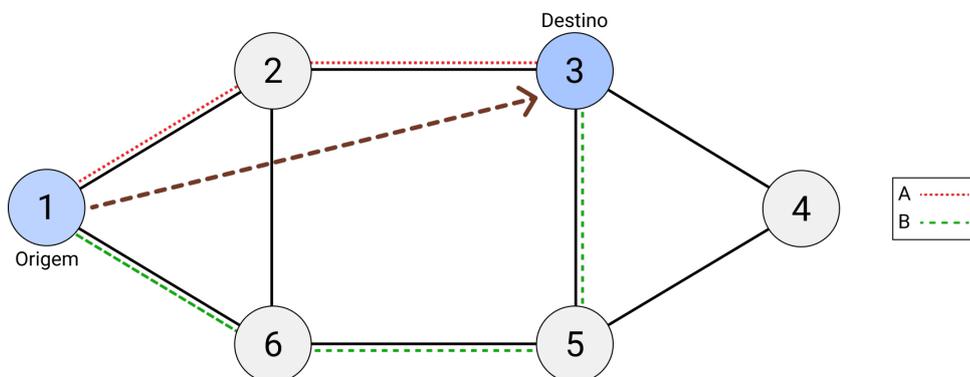
As topologias de redes são os canais nos quais estão conectados os dispositivos e os demais componentes. Essas topologias são divididas em duas categorias básicas: a física e a lógica. A topologia física é a verdadeira forma como se observa a rede conectada, podendo ser chamada *layout* da rede. Em outras palavras, é a disposição em que os cabos de fibra óptica estão conectados. A topologia lógica, por outro lado, descreve o fluxo de dados através da rede.

Representa a maneira como os sinais agem sobre os meios da rede, ou como os dados são transmitidos entre os dispositivos abstraindo-se as ligações físicas. As topologias de fibra mais utilizadas são: barramento linear, também chamado canal; anel; estrela; e configuração de malha. Cada uma dessas topologias tem suas vantagens e desvantagens em confiabilidade, capacidade de expansão, custo financeiro e desempenho (KEISER, 2014).

Para transmitir a informação de um nó da rede ao outro é necessário estabelecer uma conexão. O sinal óptico que sai do nó de origem percorre uma rota até chegar ao nó de destino. Considerando uma rede em malha, geralmente existem diversas rotas interligando cada par origem-destino, como observado na Figura 3. Nessa figura, a seta indica a conexão a ser estabelecida entre os nós 1 e 3. A rota 'A' é composta por dois enlaces $1 \mapsto 2$ e $2 \mapsto 3$, já a rota 'B' tem três enlaces $1 \mapsto 6$, $6 \mapsto 5$ e $5 \mapsto 3$. A decisão da escolha da rota utiliza como base um ou mais critérios. Esse é o chamado problema de roteamento. O problema de roteamento é uma parte fundamental do projeto de redes ópticas, visto que sua escolha afeta o desempenho de toda a rede. Em uma rede orientada a conexão, a probabilidade (P_b) de que uma requisição de conexão seja bloqueada é usada como medida de desempenho. Esse valor é obtido dividindo-se o total de requisições bloqueadas (R_b) pelo total enviado (R_e), conforme a Equação 2.1. Quanto menor a probabilidade de bloqueio, melhor será o desempenho da rede (PAIVA, 2008).

$$P_b = \frac{R_b}{R_e} \quad (2.1)$$

Figura 3 – Duas possíveis rotas para estabelecer conexão entre os nós 1 e 3.



Fonte: Elaborado pelo Autor (2021).

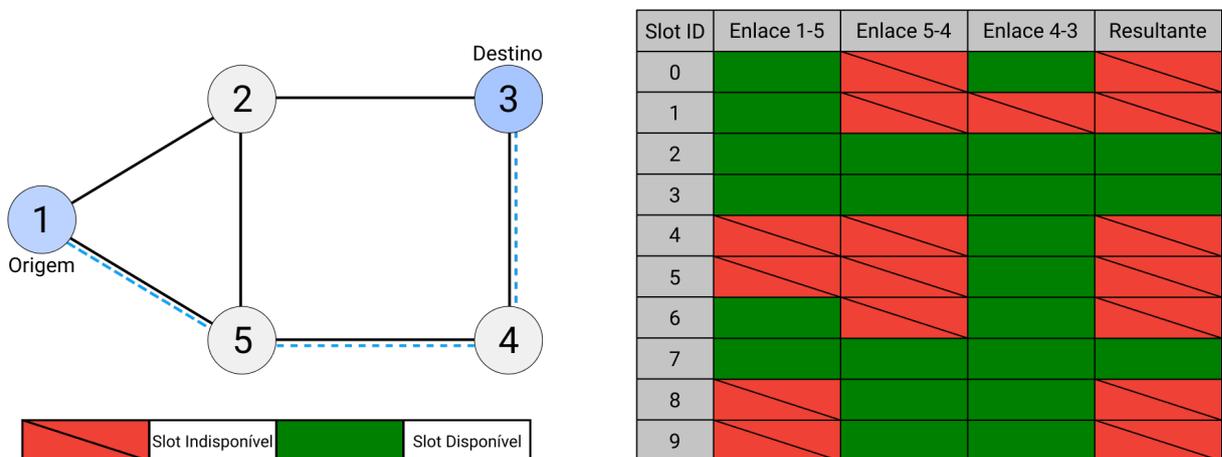
Ao longo deste capítulo serão detalhados os conceitos associados às redes ópticas elásticas, por ser o objetivo de estudo dessa pesquisa. No decorrer das próximas seções, serão explicados o problema do RSA e as contribuições da literatura para solucionar esse problema.

2.1 PROBLEMA RSA

O problema RSA consiste em encontrar um caminho óptico capaz de alocar a largura de banda do sinal transmitido, para um conjunto de demandas heterogêneas que competem por recursos de espectro. Esse problema de otimização é categorizado como *NP-Hard*. Significa dizer que não existem algoritmos capazes de resolvê-lo deterministicamente em tempo polinomial. Dessa forma, soluções de otimização que contemplem grandes cenários de rede, como: tamanho da rede, número de demandas e largura do espectro, são muito desafiadoras (KLINKOWSKI et al., 2016).

Com o problema RSA, surgem algumas restrições necessárias para o gerenciamento do espectro, são elas: continuidade e contiguidade. A continuidade implica a utilização dos mesmos *slots* de frequência em todos os enlaces que formam a rota candidata. Já o conceito de contiguidade impõe que os *slots* sejam usados sequencialmente no espectro (nos casos em que são necessários mais que um único slot) (SILVA et al., 2018). A Figura 4 mostra a restrição da continuidade de espectro para a rota $1 \mapsto 5 \mapsto 4 \mapsto 3$. Nessa figura, o *slot* disponível na cor verde e o *slot* indisponível na cor vermelho com uma linha diagonal. Esse será o padrão de representação adotado no decorrer do texto. Pode-se observar que para que o *slot* esteja disponível no vetor resultante deve esse mesmo *slot* estar livre em todos os enlaces que compõem essa rota. Para exemplificar o conceito de contiguidade, assume-se uma requisição que utiliza 3 *slots*. No vetor resultante há 3 *slots* disponíveis, mas essa requisição não pode ser alocada pois os *slots* disponíveis não estão contíguos.

Figura 4 – Exemplo de restrição de continuidade de espectro para a rota $1 \mapsto 5 \mapsto 4 \mapsto 3$.



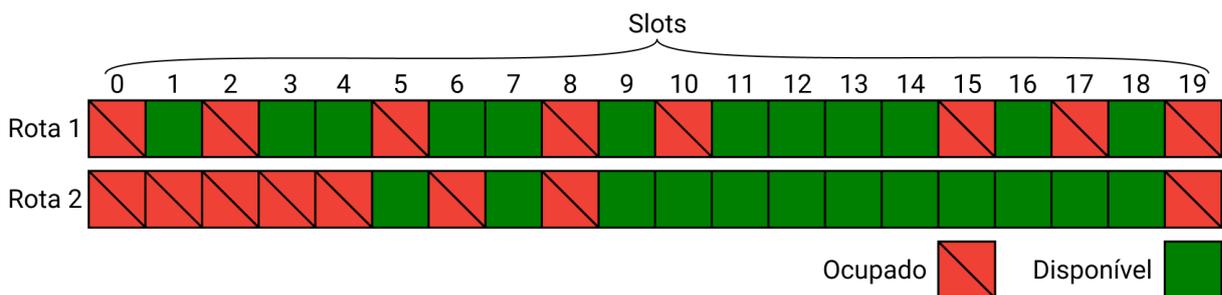
Fonte: Elaborado pelo Autor (2021). Adaptado de Figueirôa et al. (2017).

2.1.1 Fragmentação do espectro

As redes ópticas elásticas alocam as demandas em *slots* contíguos. As demandas heterogêneas necessitam de um número variado de *slots* para serem alocadas no espectro. Portanto, adicionar e retirar essas conexões pode gerar um problema de fragmentação da largura de banda (KHODASHENAS et al., 2014). A fragmentação do espectro é a condição em que há formação de lacunas no espectro. O conceito de lacuna indica a existência de *slots* contíguos disponíveis entre *slots* ocupados, cujo tamanho é definido pela quantidade de *slots* disponíveis que ela possui. Essas lacunas dificultam a alocação de solicitações futuras, portanto, bloqueando as solicitações que não conseguem encaixar nessas lacunas. Para evitar os bloqueios de largura de banda, os operadores de rede buscam otimizar a organização do espectro, de modo a reduzir a fragmentação e nos casos extremos aplicam algoritmos de desfragmentação da rede (CHATTERJEE; SARMA; OKI, 2015).

A Figura 5 mostra o problema de fragmentação. No vetor de disponibilidade da rota 1 pode-se observar a ocorrência de pequenas lacunas com *slots* disponíveis. Já no vetor de disponibilidade da rota 2, a quantidade de lacunas é menor, contendo a mesma quantidade de *slots* ocupados. Como a fragmentação de espectro é denominada pelos recursos de espectro divididos em blocos, é evidente que a rota 2 apresenta menor fragmentação que a rota 1, portanto, tende a acomodar um número maior de requisições (HOROTA, 2016).

Figura 5 – Exemplo de fragmentação do espectro no vetor de disponibilidade de uma rota.



Fonte: Elaborado pelo Autor (2021). Adaptado de Horota (2016).

O processo de fragmentação do espectro impactam as alocações de grandes demandas. Por exemplo, assumindo uma requisição que necessita de 3 *slots* para ser alocada. Considerando a rota 1, a requisição só poderá ser alocada no conjunto formado pelos *slots* de índice {11,12,13} ou {12,13,14}, respeitando o princípio da contiguidade.

2.1.2 Roteamento

A escolha da rota depende do algoritmo de roteamento utilizado. O estado da rede considera as conexões ativas e os recursos disponíveis como métricas para obter as melhores rotas. Os algoritmos podem ou não considerar o estado atual da rede ao realizar suas escolhas, sendo denominados adaptativos (ou dinâmicos) e estáticos, respectivamente. Os algoritmos de roteamento estáticos são mais simples e calculados de forma *offline*. Diversas métricas podem ser usadas como custo para a obtenção das melhores rotas e as comuns são: distância, número de enlaces, número de amplificadores, quantidade de regeneradores, entre outros. As rotas escolhidas são armazenadas em uma tabela de roteamento para todos os pares origem-destino (O-D) da rede. Dois exemplos de algoritmos para roteamento estático são: o roteamento fixo, em que sempre é escolhida a mesma rota para um determinado par O-D; e o roteamento fixo-alternativo, em que a rota para um dado par O-D é escolhida de forma sequencial a partir de uma lista ordenada de caminhos pré-determinados. Nos algoritmos de roteamento dinâmico as rotas são escolhidas a depender do estado da rede (XAVIER, 2016).

Os algoritmos mais populares na literatura que recorrem ao roteamento fixo são o algoritmo do caminho mais curto (SP, do inglês *Shortest Path*) e o algoritmo de mínimos saltos (MH, do inglês *Minimum Hop*). É comum em ambos os algoritmos de roteamento o uso do algoritmo *Dijkstra* (DIJKSTRA et al., 1959) para encontrar a menor rota com base no custo do enlace. A função custo do algoritmo SP é definida como a distância física entre nós, de forma que o algoritmo retorna a rota mais curta em termos da distância física. Já para o algoritmo MH, a função custo é unitária para cada enlace da rede, sendo assim, a menor rota será aquela que tiver menos enlaces.

Em Yen (1971) foi proposto um algoritmo capaz de encontrar as k -rotas de menor caminho entre os nós de origem e destino. O Yen utiliza os algoritmos de caminho mais curto, por exemplo, o SP ou MH, para formar um conjunto conforme a métrica desejada. O custo computacional do algoritmo Yen cresce conforme o aumento do número de rotas solicitadas. Em Santos, Almeida-Jr. e Assis (2014) os autores recorrem ao Yen-MH para apresentar o algoritmo de Melhor Entre as Rotas Mais Curtas (BSR, do inglês *Best Among the Shortest Routes*), denominado Yen-BSR. O BSR adota um processo iterativo para selecionar, entre as rotas encontradas pelo Yen-MH, uma lista de rotas para cada par O-D que por utilizar esses caminhos de forma fixa durante toda operação da rede, sendo denominado como algoritmo de roteamento fixo-alternativo. O algoritmo Yen-BSR resulta em um balanceamento de carga

entre os links da rede, com o intuito de minimizar a probabilidade de bloqueio.

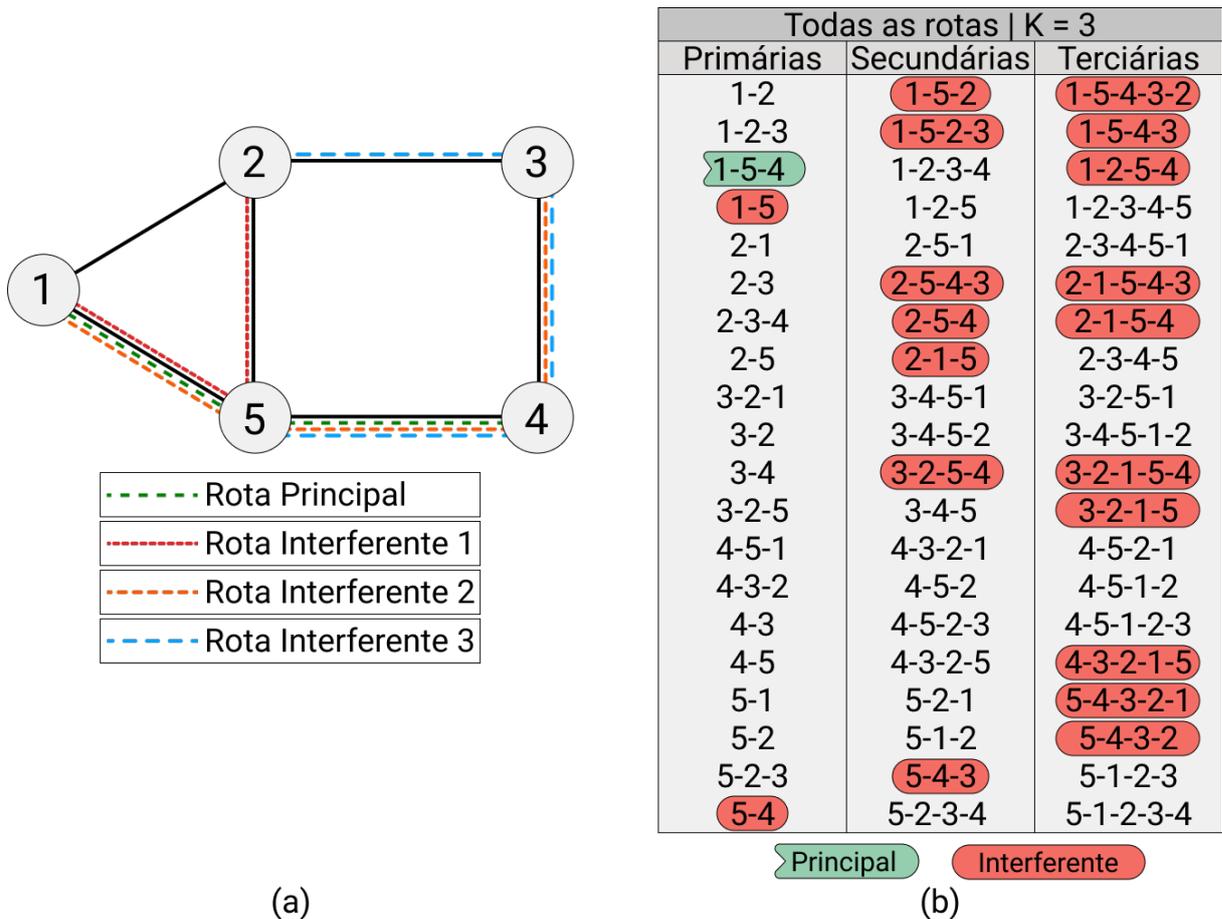
Na categoria de algoritmos com o roteamento adaptativo pode-se citar o algoritmo de Roteamento por Série de Potência (PSR, do inglês *Power Series Routing*), detalhado em Cavalcante et al. (2018). Nesse algoritmo o custo dos enlaces que compõem a rede é obtido seguindo quatro passos. O primeiro passo é a definição dos parâmetros de entrada. Para os parâmetros, podem ser usadas as mais diversas combinações, a exemplo da disponibilidade do enlace e a distância física. O segundo passo visa representar os parâmetros de entrada na forma de uma série de potências. No terceiro passo é escolhida uma função de avaliação para mensurar o desempenho dos coeficientes da série. Por fim, é escolhida uma técnica de otimização para esses coeficientes. O treinamento dos coeficientes é realizado na fase de planejamento e os melhores serão usados durante a fase operacional.

2.1.2.1 Conjunto de rotas interferentes

O conceito do conjunto de rotas interferentes é de extrema importância no decorrer deste trabalho. Duas rotas são chamadas interferentes ou conflitantes quando ao menos um dos enlaces que compõem uma das rotas também está presente na outra. Cada rota sob um algoritmo de roteamento que escolhe uma ou mais rotas entre os pares de nós tem um conjunto de caminhos que são conflitantes com ela. O tamanho desse conjunto cresce conforme a quantidade de rotas para cada par origem-destino aumenta.

A Figura 6 (a) apresenta 4 exemplos de rotas interferentes aplicadas a uma topologia genérica. Com essa Figura é demonstrado um exemplo do conceito de rotas interferentes, ao apresentar caminhos que compartilham alguns enlaces com outras, mas não todos; e caminhos em que todos seus enlaces também pertencem a outras rotas. Neste caso, diz que a rota está contida na outra. Na Figura 6 (b) são apresentadas todas as rotas obtidas pelo algoritmo de roteamento Yen-MH, encontrando 3 rotas para o mesmo par origem-destino ($K = 3$). As colunas da tabela estão separadas pela ordem em que as rotas são encontradas pelo algoritmo de roteamento. Ao fornecer o parâmetro $K = 1$ para o algoritmo, somente as 20 rotas presentes na coluna “Primárias” serão encontradas, já usando $K = 2$ são encontradas 40 rotas presentes na coluna “Primárias” e “Secundárias”, seguindo a lógica para $K = 3$. Ao considerar o caminho formado pelos nós $1 \mapsto 5 \mapsto 4$ como caminho principal e analisando a quantidade de rotas interferentes a ela, temos: 2 rotas no conjunto criado por $K = 1$, aumentando para 9 em $K = 2$ e 19 no conjunto formado por $K = 3$.

Figura 6 – Exemplo de rotas interferentes.



Fonte: Elaborado pelo Autor (2021).

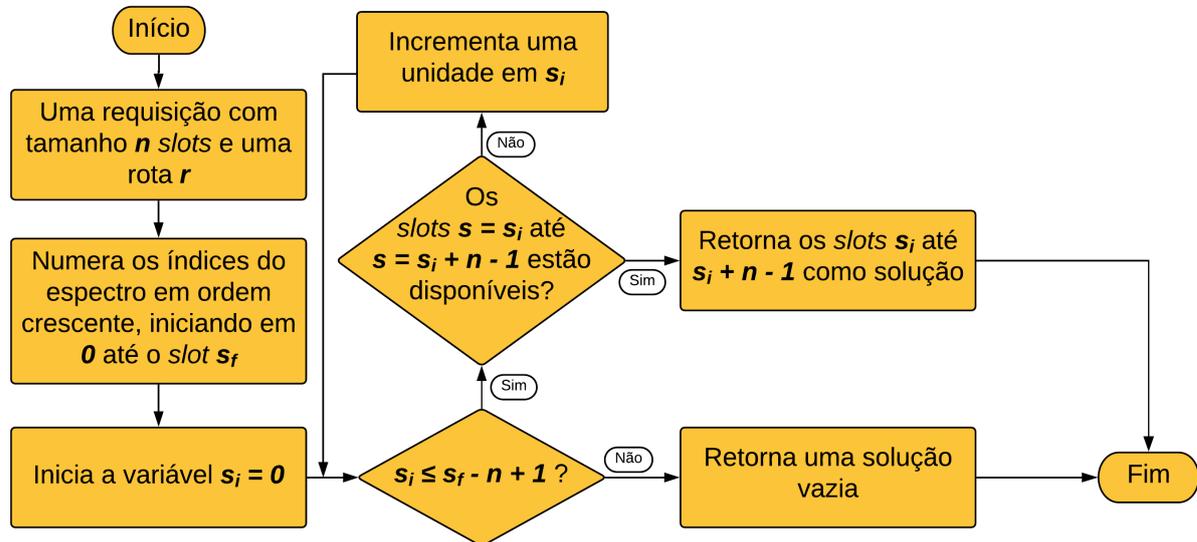
2.1.3 Alocação de espectro

Algumas heurísticas foram adaptadas do problema RWA de redes WDM para o RSA de EONs. Exemplos de heurísticas adaptadas são a *Random* e a *First-Fit*. Na heurística *Random*, são escolhidos conjuntos de *slots* aleatórios que estejam disponíveis. Já no *First-Fit*, uma lista de alocação é gerada e os conjuntos de *slots* são escolhidos conforme a ordem da lista (FILHO, 2018).

O *First-Fit* é uma política de alocação de espectro amplamente utilizada na literatura, presente em diversos trabalhos (RUIZ et al., 2017; RAMASWAMI; SIVARAJAN; SASAKI, 2009). O funcionamento da heurística para EONs é apresentado na Figura 7. Inicialmente, cada *slot* de frequência presente no espectro da rota recebe um índice, seguindo uma ordem crescente. A cada requisição de conexão, esses índices são percorridos até encontrar o primeiro conjunto de *slots* capaz de acomodar uma demanda de tamanho n (utiliza n *slots* de frequência para acomodar a requisição), ou até que o fim da lista seja alcançado. As propriedades de continuidade

e contiguidade devem ser respeitadas para validar o conjunto encontrado. A popularidade do algoritmo deve-se ao compromisso entre simplicidade e eficiência.

Figura 7 – Fluxograma da heurística *First-Fit*.



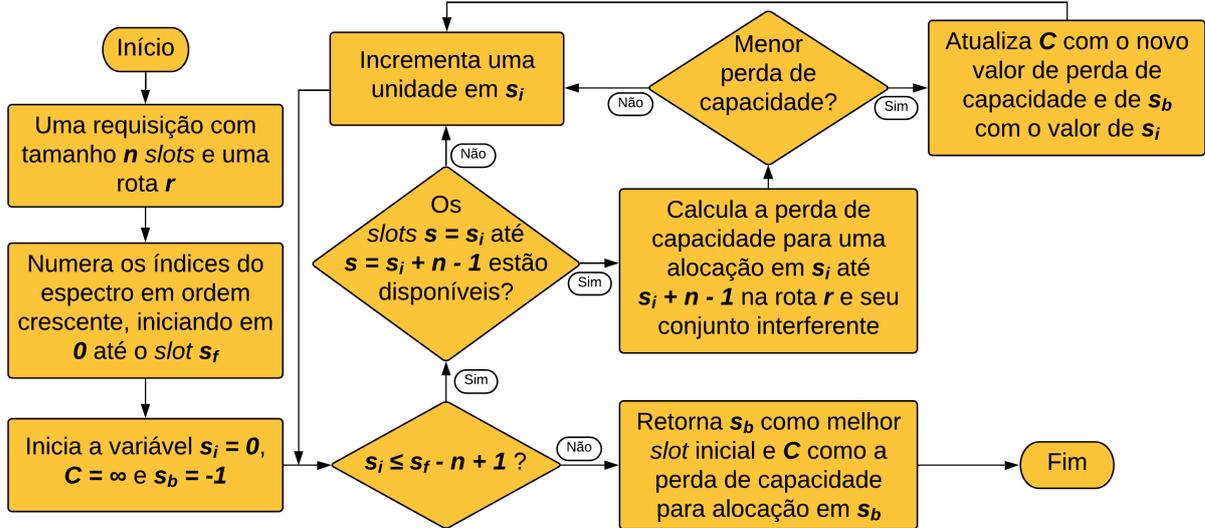
Fonte: Elaborado pelo Autor (2021).

Em Almeida-Jr. et al. (2013) foi apresentado o algoritmo de alocação de espectro MSCL. O objetivo do MSCL é analisar, para cada requisição, o estado dos possíveis caminhos ópticos na rede de modo a obter o melhor conjunto de *slots* para alocar a requisição, de modo que a perda de capacidade seja a menor possível, reduzindo dessa forma a probabilidade de bloqueio das requisições subsequentes. Diversos trabalhos aplicaram essa heurística adaptada a novos problemas, como: aplicação em Fibras Multi-Núcleo (FILHO; ALMEIDA-JR, 2018); combinado com a técnica de *Split Spectrum* (LIRA; ALMEIDA-JR.; CHAVES, 2020) e avaliando a fragmentação do espectro (LIRA et al., 2020).

2.1.3.1 Algoritmo MSCL

O MSCL é um algoritmo de alocação de espectro usado em EONs. Conforme detalhado em Filho e Almeida-Jr (2018) e Lira, Almeida-Jr. e Chaves (2020), sua premissa se baseia na escolha do melhor conjunto de *slots* que, ao serem alocados na rede, irá minimizar o impacto em perda de capacidade de alocação. Para cada solicitação de requisição, é feito o cálculo considerando a rota principal da requisição a ser alocada, com todas as rotas que compartilham ao menos um enlace com ela. A Figura 8 apresenta o fluxograma para a sequência lógica da heurística MSCL.

Figura 8 – Fluxograma da heurística MSCL.



Fonte: Elaborado pelo Autor (2021).

A perda de capacidade está diretamente associada à fragmentação do espectro, apresentada na Seção 2.1.1. A maneira pela qual este trabalho calcula a perda de capacidade é baseada no número de formas possíveis para alocar uma requisição em uma lacuna. Caso uma lacuna apresente tamanho igual ou superior à quantidade de *slots* necessários para acomodar a requisição, é possível encontrar o número de formas para alocar um conjunto de *n slots*. Caso o tamanho da lacuna seja inferior a *n* o número de formas será igual a 0.

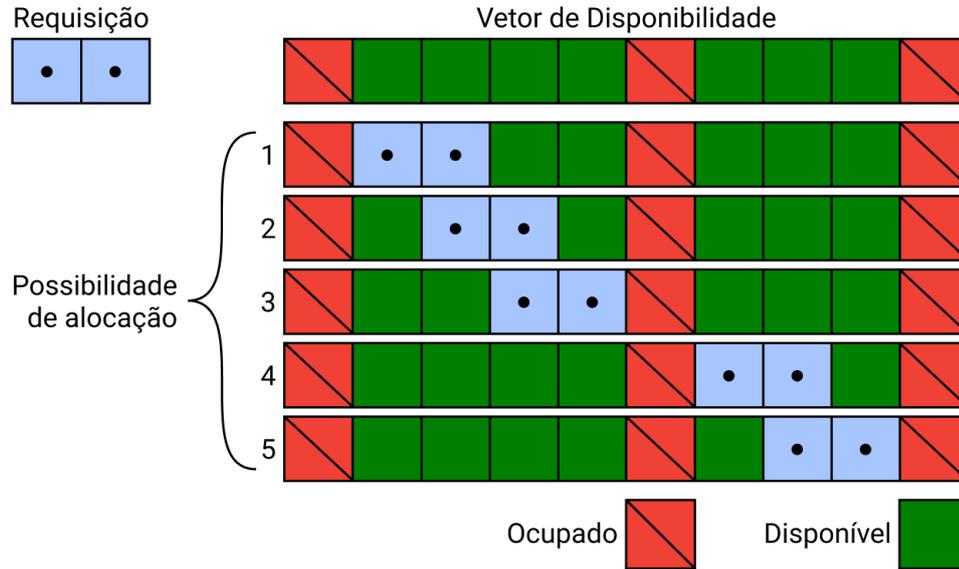
A Figura 9 demonstra um exemplo para uma rota com 10 *slots* e uma requisição por $n = 2$ *slots*. Na cor azul, são representados os possíveis *slots* para a requisição a ser alocada. Existem 5 possibilidades de alocação para esse exemplo. Esse valor pode ser obtido conhecendo os tamanhos e as quantidades das lacunas. Nesse exemplo, há uma lacuna de tamanho 4 e outra de tamanho 3. Assim, o número de formas é definido como:

$$S^{<r>}(\psi, n) = \sum_{l \in L} \max(0, h_l - n + 1), \quad (2.2)$$

em que: $S^{<r>}(\psi, n)$ é o número de formas como uma requisição de tamanho *n* pode ser alocada em uma rota *r*; *L* é o conjunto de todas as lacunas presentes no vetor de disponibilidade; e h_l é tamanho da lacuna *l*.

A perda de capacidade é obtida por meio da comparação deste valor antes e depois de uma possível alocação para uma demanda de *n slots* em uma rota *r* e todo seu conjunto de rotas interferentes, sendo calculado por:

Figura 9 – Representação das possibilidades de alocação para uma requisição de 2 slots no vetor de disponibilidade.



Fonte: Elaborado pelo Autor (2021). Adaptado de Filho (2018).

$$C^{<r>}(n) = \sum_{p \in (I_r \cup r)} [S^{<p>}(\psi, n) - S^{<p>}(\psi', n)], \quad (2.3)$$

em que: $C^{<r>}(n)$ é a perda de capacidade para requisição com n slots após o estabelecimento na rota r ; I_r é o conjunto de rotas que interferem com a rota r ; p é a rota interferente atual; ψ representa o estado atual da rede (ou seja, o conjunto de todos os caminhos e slots alocados); ψ' representa o estado da rede após o estabelecimento da requisição em r ; $S^{<p>}(\psi, n)$ é o número total de possibilidades de alocação que uma requisição por n slots tem para alocar no caminho p antes do estabelecimento de r ; e $S^{<p>}(\psi', n)$ é o número total de possibilidades de alocação que uma requisição por n slots tem para alocar no caminho p após estabelecimento de r .

A Equação 2.3 calcula o impacto sofrido por uma requisição de tamanho n sobre a rota r e todas as que interferem com ela. Para obter a perda de capacidade total na rede é necessário considerar todas as demandas possíveis para a rota r . Assim, o cálculo é dado por:

$$C^{<r>} = \sum_{n \in N} C^{<r>}(n), \quad (2.4)$$

em que N é o conjunto de todas as possíveis classes de demandas que podem ser alocadas em r e $C^{<r>}$ representa a perda de capacidade total para todo o conjunto N . A posição espectral que obtiver o menor $C^{<r>}$ obtido pela Equação 2.4 será a posição de alocação da requisição.

3 HEURÍSTICAS PROPOSTAS

O problema de roteamento e alocação de espectro, apresentado no Capítulo 2, necessita que heurísticas determinem a posição do espectro onde cada requisição deverá ser alocada de forma a minimizar os efeitos negativos na rede. Com base nessa problemática as heurísticas propostas neste trabalho são uma adaptação do algoritmo MSCL para redes apresentadas em Almeida-Jr. et al. (2013). Em todos os trabalhos relacionados aqui apresentados, que usam o MSCL, o algoritmo foi aplicado a uma única rota com a finalidade de encontrar o melhor conjunto de *slots* para alocar a requisição. Nesses trabalhos a comparação entre as heurísticas é realizada usando somente a probabilidade de bloqueio como métrica. Sabendo que o MSCL é um algoritmo mais custoso que o *First-Fit*, o tempo de simulação é usado para medir a complexidade entre os algoritmos.

Utilizando as heurísticas propostas, a principal diferença está na forma de escolher entre diversas perdas de capacidade em múltiplas rotas. As duas propostas apresentadas ao longo desta seção recebem o nome de MSCL Sequencial e MSCL Combinado, associando a forma como elas calculam a perda de capacidade entre o conjunto de rotas. Inicialmente, é obtido um conjunto de K rotas para cada par origem-destino de forma *offline*. Esse conjunto ao ser armazenado deve manter a ordenação entre as rotas conforme a métrica utilizada para encontrá-las, de forma que a primeira rota terá o menor custo e a última o maior custo. Ambas as heurísticas utilizam esse mesmo procedimento inicial para obtenção das rotas, no entanto, a ordem entre as rotas é indiferente para o MSCL Combinado.

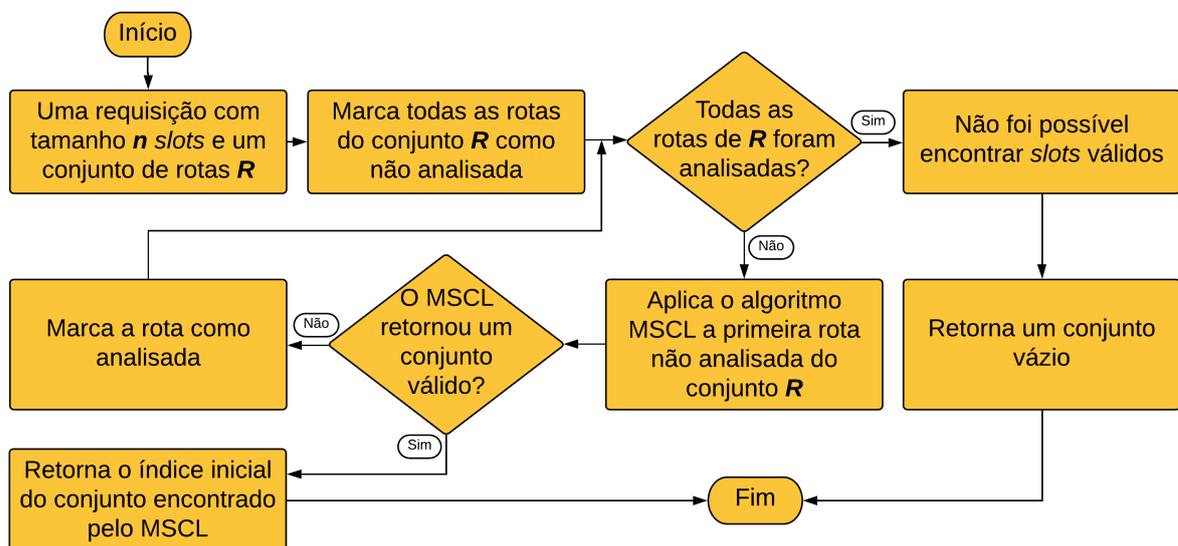
3.1 MSCL SEQUENCIAL

A primeira proposta, intitulada MSCL Sequencial, recebe esse nome devido à maneira como utiliza o conjunto de k -rotas para um mesmo par origem-destino. Esse conjunto chega à heurística ordenado a partir da métrica estabelecida no algoritmo de roteamento fixo-alternativo. A tentativa de alocação da requisição é feita na primeira rota do conjunto ($k = 1$), aplicando o algoritmo base do MSCL nessa rota e em todo seu conjunto de rotas interferentes. Caso essa rota apresente recursos suficientes para alocação, isto é, haja ao menos um conjunto de *slots* disponíveis para alocar a requisição, o conjunto que provê a menor perda de capacidade nesta rota é usado. Caso o caminho analisado não tenha recursos suficientes para a alocação,

a tentativa é feita nas rotas com valores de k subsequentes, seguindo o ordenamento.

Quando todas as rotas são testadas e não se obtém sucesso na alocação, ocorre o bloqueio da requisição por falta de recursos na rede. Devido à lógica da heurística, o MSCL Sequencial tende a utilizar todos os recursos presentes na primeira rota antes de analisar a próxima. Sendo essas rotas mais curtas em quantidade de enlaces, elas normalmente interferem com os demais caminhos da rede em menor quantidade, visto que normalmente contêm um conjunto de rotas interferente menor que as rotas com mais enlaces. A Figura 10 mostra o fluxograma com o detalhamento da lógica de funcionamento da heurística MSCL Sequencial para um conjunto de k -rotas. Esse fluxograma recorre ao algoritmo base, mostrado na Figura 8.

Figura 10 – Fluxograma para a heurística MSCL Sequencial.



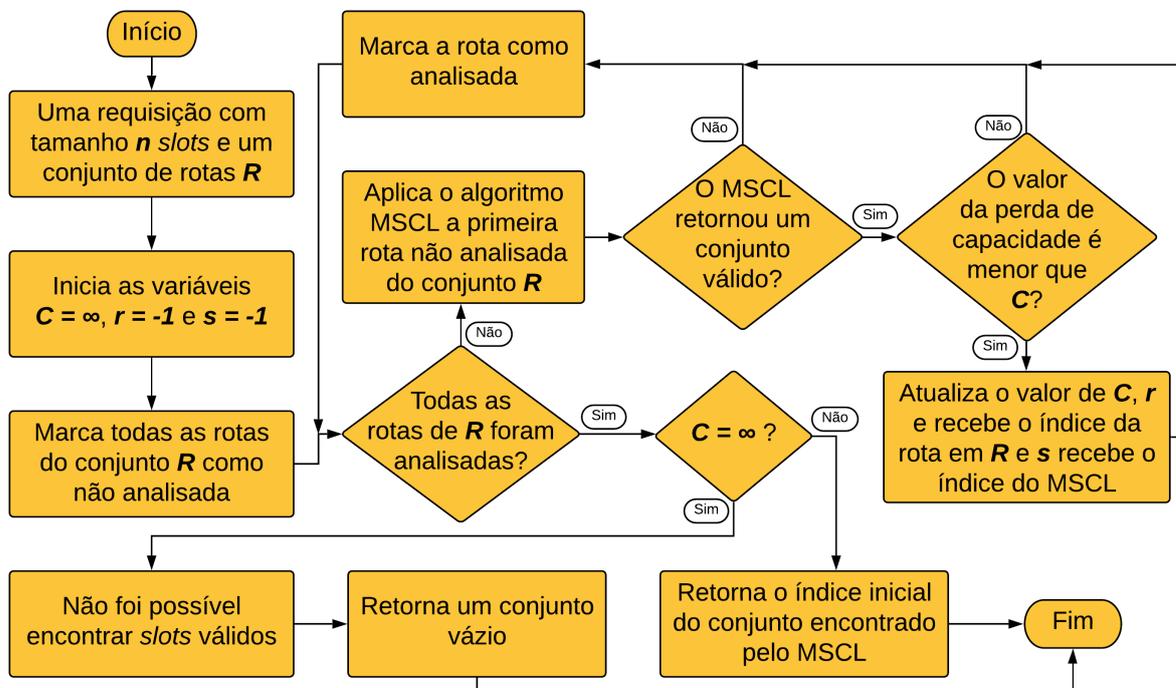
Fonte: Elaborado pelo Autor (2021).

3.2 MSCL COMBINADO

A segunda proposta, o MSCL Combinado, é uma expansão da heurística MSCL Sequencial. Nesta proposta, diferente da primeira, todas as k -rotas serão analisadas no primeiro momento, encontrando o melhor local no espectro para alocação e o seu respectivo valor de perda de capacidade. Após encontrado e armazenados esses valores para todas as k -rotas, a heurística identifica o caminho que apresentou a menor perda de capacidade dentre o conjunto computado, retornando a rota e o conjunto de $slots$ responsável por obter esse valor. O Fluxograma 11 detalha a lógica para o funcionamento da heurística MSCL Combinado, recorrendo ao algoritmo base, mostrado na Figura 8.

O passo a passo do fluxograma da Figura 11 é iniciado recebendo uma requisição de tamanho n e um conjunto de rotas R . Variáveis de controle são iniciadas para armazenar e controlar o fluxo do algoritmo. A variável C armazena o menor valor da perda de capacidade encontrada para a rota r , iniciando a alocação no *slot* de índice s . Os valores de r e s são iniciados em -1 por não serem valores válidos e C recebe infinito, já que qualquer valor encontrado será melhor sendo substituído nessa variável. O algoritmo segue percorrendo e aplicando o algoritmo MSCL base em todas as rotas do conjunto, caso o valor da perda de capacidade seja o menor encontrado, é armazenado o índice da rota e do slot para serem posteriormente retornados pela heurística.

Figura 11 – Fluxograma para a heurística MSCL Combinado.



Fonte: Elaborado pelo Autor (2021).

A necessidade de analisar todas as rotas do conjunto torna o MSCL Combinado computacionalmente mais complexo que o MSCL Sequencial. Naturalmente, essa complexidade demandará mais tempo de execução para o ciclo das requisições. No entanto, por ter um olhar global sobre todo o conjunto, o MSCL Combinado pode optar em alocar a requisição em um caminho mais longo que apresente um impacto menor a rede, mesmo esse caminho interferindo com mais rotas ao longo da topologia.

A Figura 12 apresenta a política de escolha das heurísticas propostas nesta dissertação e o *First-Fit* para um certo instante da rede. Nesse cenário com $k = 3$, foi exemplificada a perda de

capacidade de 4 conjuntos de *slots*. O *First-Fit*, mostrado em azul, escolhe o primeiro conjunto disponível para a primeira rota, já o MSCL Sequencial, representado na cor amarela, escolhe o conjunto com a menor perda de capacidade para a primeira rota. O MSCL Combinado, no que lhe concerne, consegue analisar todos os conjuntos de *slots* em cada uma das rotas, escolhendo a combinação que apresentar o menor impacto na rede.

Figura 12 – Exemplo de alocação das heurísticas abordas nesta dissertação.

	Conjunto de slots			
	A	B	C	D
Rota 1	58	64	54	56
Rota 2	65	50	60	57
Rota 3	72	74	85	78

First-Fit	MSCL S	MSCL C
-----------	--------	--------

Fonte: Elaborado pelo Autor (2021).

3.3 PROCEDIMENTO EXPERIMENTAL

Para avaliação das propostas deste trabalho, foram realizados experimentos computacionais auxiliados por um simulador de redes ópticas elásticas. O simulador utilizado é uma adaptação para EONs do simulador SIMTON (CHAVES et al., 2010), utilizando ferramentas presentes no simulador SimEON (CAVALCANTE; PEREIRA; ALMEIDA-JR., 2017) e escrito na linguagem de programação Java. A aferição do simulador foi realizada reproduzindo os resultados do artigo Dinarte et al. (2021) visando obter os mesmos resultados. Os parâmetros utilizados na configuração do simulador estão disponíveis na Tabela 1, facilitando a reprodução dos resultados apresentados nessa pesquisa.

Tabela 1 – Parâmetros de configuração do simulador.

Descrição	Valor
Quantidade de <i>slot</i> por enlace	128
Número de requisições solicitadas	10 ⁶
Polarização	2
Espaçamento de frequência do <i>slot</i> (Gb/s)	12,5
Duração média da chamada	1
Modulação	8-QAM

Fonte: Autor.

A quantidade de *slots* por enlace mostrada na Tabela 1 foi obtido de forma empírica, sendo os valores comumente utilizados na literatura. Para cada simulação foram utilizadas 10^6 requisições, garantindo que ocorram ao menos 1000 bloqueios nas requisições enviadas para assegurar a confiabilidade dos resultados. O tráfego de chegada assume um modelo Poissoniano e a duração das requisições segue uma distribuição exponencial. As simulações utilizam somente camada de rede, seguindo a linha dos trabalhos anteriores sobre o MSCL. O formato de modulação considerado foi 8-QAM e os nós de origem e destino são escolhidos a partir de uma função de densidade de probabilidade Uniforme, assim como a taxa de transmissão sorteada a cada requisição. Essa taxa assume os seguintes valores: 100, 200 e 400 Gbits/s.

Um *slot* ocupa uma frequência de 12,5 GHz e, seguindo a equação 3.1 mostrada em Alves et al. (2021), é possível obter a demanda necessária para alocar a requisição com taxa de transmissão B .

$$n = \frac{B}{P \cdot B_{slot} \cdot \log_2 X}, \quad (3.1)$$

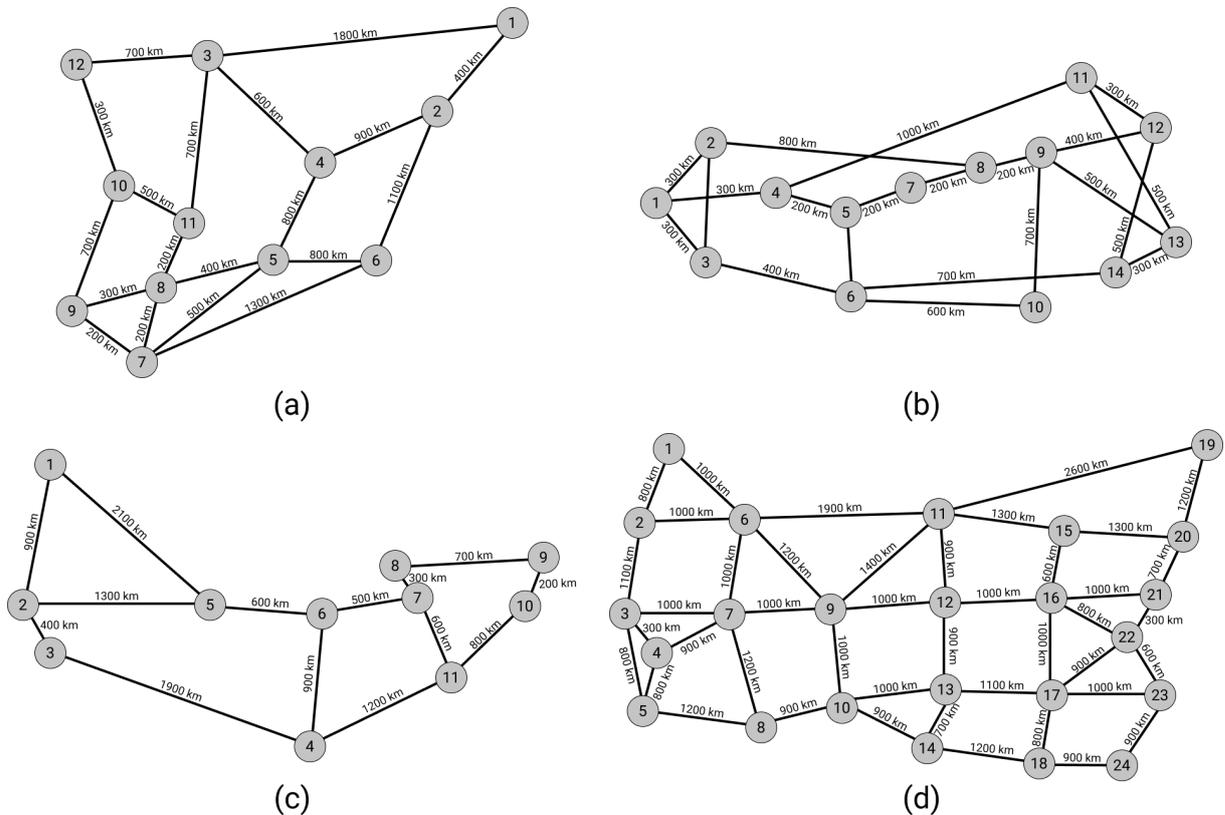
em que: X representa a constelação da modulação utilizada e P indica se uma ou duas polarizações são usadas. Sendo assim, as demandas de 2, 3 e 6 *slots* são obtidas para as respectivas taxas utilizadas.

Para permitir uma avaliação mais abrangente dos benefícios de cada heurística proposta, foram consideradas quatro topologias irregulares diferentes com enlaces unidirecionais, conforme ilustra a Figura 13. A Finlândia e NSFNet são as principais topologias utilizadas no decorrer desta dissertação, sendo a Abilene e USANet usadas para validação das propostas em diferentes cenários de número de nós.

No roteamento, foi escolhido o algoritmo Yen-MH (YEN, 1971) para encontrar as K menores rotas. O desempenho dos algoritmos foi medido a partir da probabilidade de bloqueio e tempo de simulação. Os bloqueios ocorrem quando não há um conjunto de *slots* disponíveis para alocar a requisição. O computador usado para as simulações é um i5-8265U de oitava geração com frequência de 1,6 GHz e 8 núcleos, 8 Gb de memória RAM DDR4 de 2666 MHz, armazenamento com SSD padrão M2 e placa gráfica nvidia geforce 230mx de 1 Gb.

O algoritmo escolhido para critério de comparação foi o *First-Fit*, por ser uma heurística bastante explorada e validada em diversas pesquisas com aplicações em redes WDM e EON. O *First-Fit* é um algoritmo simples, requer baixo esforço computacional e apresenta uma característica importante para redes EON no que diz respeito à compactação do espectro.

Figura 13 – Representação das topologias: (a) Finlândia com 12 nós, (b) NSFNet com 14 nós, (c) Abilene com 11 nós e (d) USANet com 24 nós.



Fonte: Elaborado pelo Autor (2021).

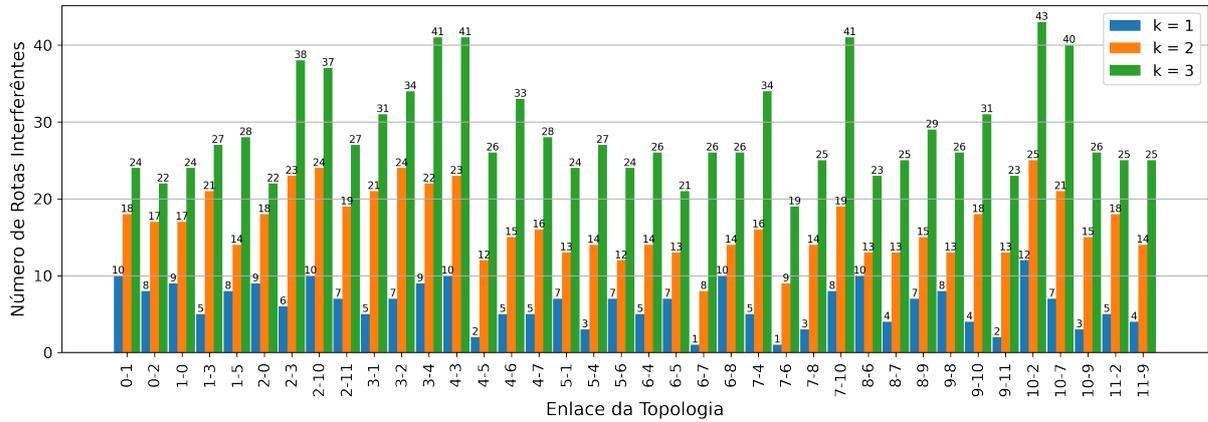
Com isso, consegue fornecer bons resultados na busca por recursos espectrais em um baixo tempo de execução. Como o tempo de execução é umas das métricas consideradas no estudo, a técnica comumente utilizada de interromper a simulação após um determinado número de bloqueio não será utilizada.

3.4 RESULTADOS

Nos primeiros estudos sobre a heurística MSCL foi observado que duas variáveis impactam diretamente o desempenho do algoritmo, são elas: o número de *slots* de frequência e o tamanho do conjunto de rotas interferentes. O número de *slots* de frequência é fixo e é definido pelas configurações do simulador. O tamanho do conjunto interferente escala com a quantidade de rotas que interligam o par origem-destino, entretanto, esse valor sofre grande oscilação conforme observa-se no gráfico da Figura 14.

A Figura 14 apresenta o aumento do conjunto interferente e sua relação conforme a variação do k para todos os enlaces da topologia Finlândia, mostrada na Figura 13 (a). Em $k = 3$ há

Figura 14 – Número de rotas interferentes encontradas por enlace para a topologia Finlândia.



Fonte: Elaborado pelo Autor (2021).

um enlace que tem somente 19 rotas interferentes, como há outro par que contém 43 rotas no conjunto interferente. Essa diferença representa uma variação de 226%, dificultando a representação do desempenho do algoritmo através de formulação matemática ou algoritmos de complexidade computacional como o *Big O* (CHIVERS; SLEIGHTHOLME, 2015). A escolha de representar somente os enlaces deve-se à abundância de caminhos presente nessa topologia. O cálculo do total de rotas é obtido pela Equação 3.2:

$$R_t = (T_{node}^2 - T_{node}) \cdot K, \quad (3.2)$$

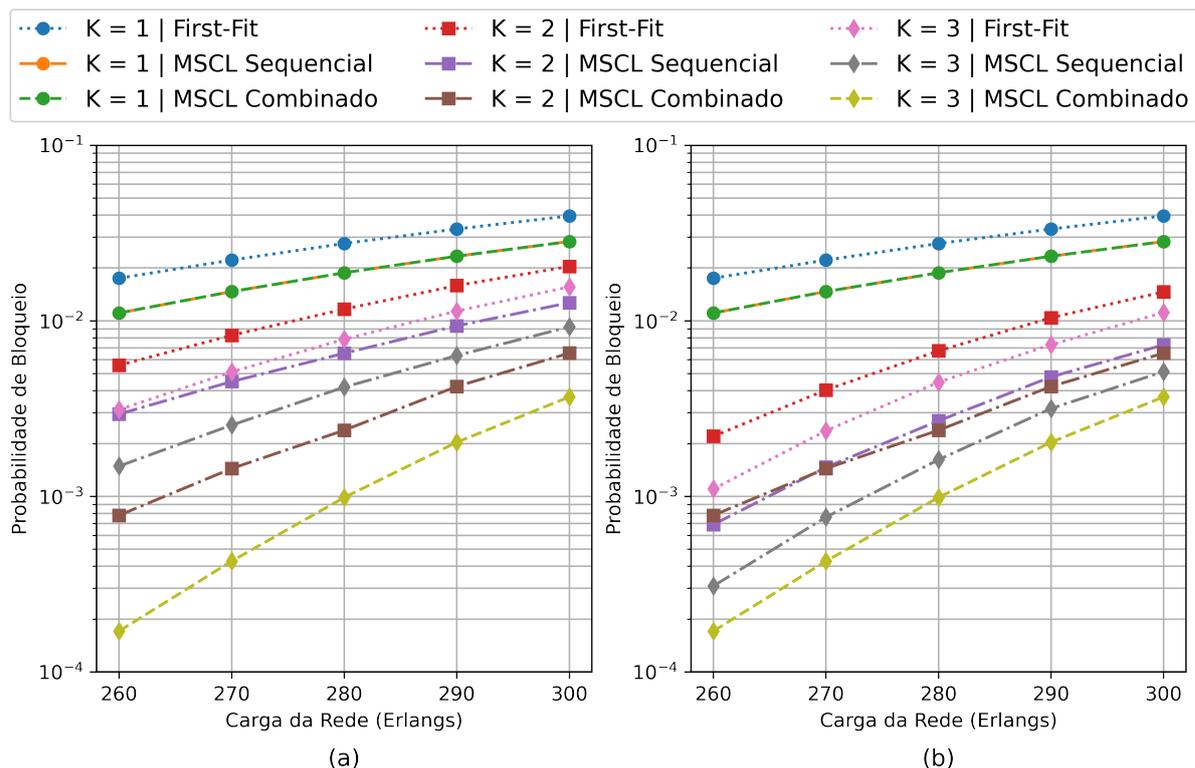
em que: R_t é o total de rotas para a topologia; T_{node} é o número de nós da rede e K a quantidade de rotas por par origem-destino. Para a topologia da Finlândia, que contém 12 nós e usando $k = 3$ há um total de 396 rotas. Dentro desse conjunto a rota composta pelos nós $3 \mapsto 4 \mapsto 7 \mapsto 10 \mapsto 2 \mapsto 11$ contém 180 rotas interferentes, com todo o conjunto apresentando uma média de 86 rotas interferentes.

A Figura 15 apresenta os resultados obtidos como probabilidade de bloqueio em relação à carga da rede para os algoritmos considerados no estudo. A Figura 15 (a) utiliza o roteamento fixo alternativo de caminho mais curto pelo menor número de enlaces. Fazendo a comparação dos algoritmos para uma única rota ($k = 1$), os algoritmos MSCL Sequencial e Combinado apresentam o mesmo desempenho, conforme esperado pela natureza das suas heurísticas. Em todas as cargas simuladas, o desempenho dos algoritmos propostos apresentaram melhoria em relação ao *First-Fit*. Observando as heurísticas em $k = 2$, o *First-Fit* melhora o desempenho, superando até mesmo os algoritmos *MSCL* com $k = 1$. A melhora encontrada utilizando o *MSCL* Sequencial, que na carga de 280 Erlangs, apresentou uma melhoria de 43,97% quando

comparado ao *First-Fit*. Ao comparar o MSCL Combinado com o *First-Fit*, a melhoria foi de 79,58%. Para $k = 3$ essa relação foi mantida em 46,63% e 87,43%, respectivamente.

De modo a evitar a suspeita de que a melhoria expressiva do MSCL Combinado advém da distribuição de carga entre as rotas e não propriamente da alocação combinada rota e lacuna com menor perda de capacidade, foi feita uma análise que ordena as K rotas antes da aplicação do *First-Fit* e do MSCL Sequencial (o desempenho do MSCL Combinado é indiferente à ordenação ou não das rotas), dando-se prioridade à rota menos congestionada, conforme apresentado na Figura 15 (b). Em $k = 1$, o desempenho foi mantido, conforme esperado. Para $k = 2$, as heurísticas propostas continuaram a apresentar melhorias em comparação ao *First-Fit* em todos os pontos simulados.

Figura 15 – Topologia NSFNet: (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir da menor ocupação WDM.



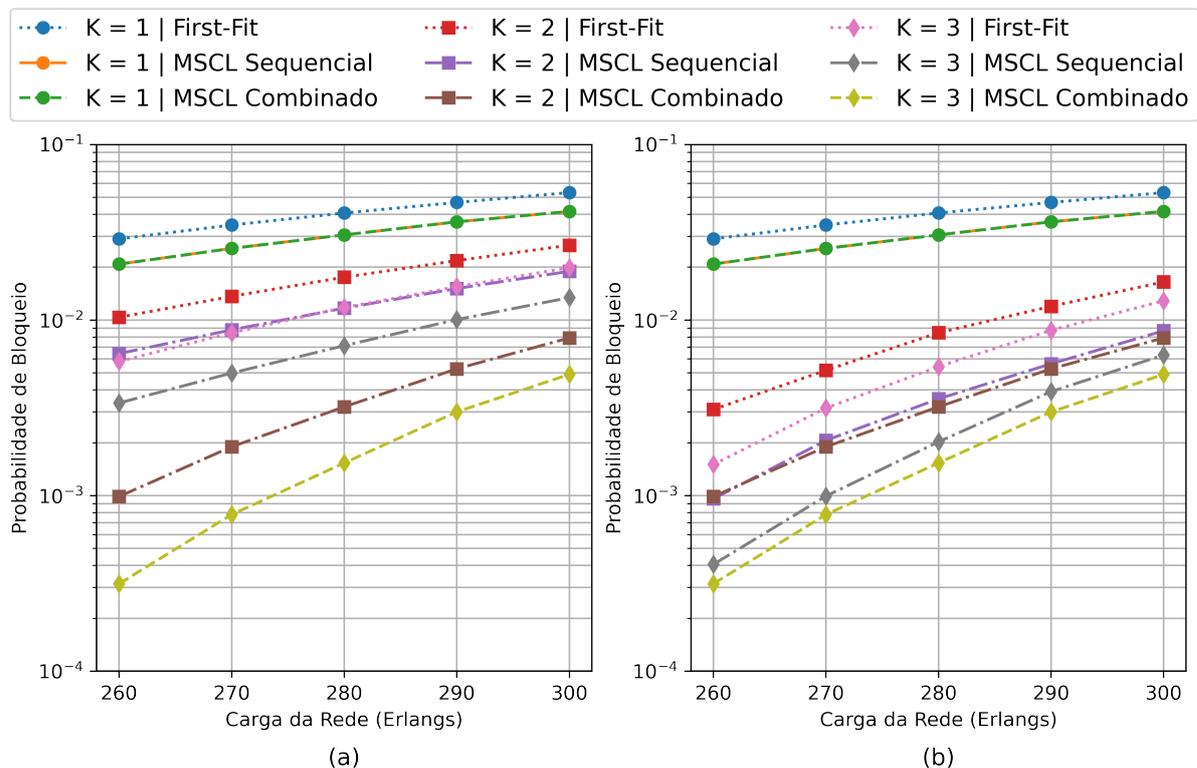
Fonte: Elaborado pelo Autor (2021).

Na carga de 280 Erlangs, a melhoria em relação ao *First-Fit* foi de 60,06% e de 64,70% para o MSCL Sequencial e o Combinado, respectivamente. Para $k = 3$, a consistência entre os algoritmos foi mantida, apresentando melhoria de 63,82% e 77,94%, respectivamente. Empates ocorridos na menor perda de capacidade em diferentes rotas são desempatados pelas rotas com a menor ocupação. Sendo assim, mesmo após aplicar um algoritmo que distribua a

carga, as heurísticas propostas ainda se mantêm melhores que o *First-Fit*, para reduzir a probabilidade de bloqueio. Nesse caso, ambos os algoritmos propostos apresentam melhorias significativas comparados ao *First-Fit*. Ao dar preferência a uma rota menos congestionada, o MSCL Sequencial terá mais opções para fazer a escolha espectral. Em $k = 2$ é possível observar uma inversão de desempenho entre as heurísticas propostas em cargas menores. Esse fato deve-se a priorização de uma rota menos ocupada utilizando requisições que liberam o espectro mais rapidamente.

Essas análises também foram realizadas para a topologia Finlândia, conforme mostrado na Figura 16 (a) para rotas ordenadas a partir do menor número de enlaces e na Figura 16 (b) para ordenamento seguindo a menor ocupação. Nessa topologia, as diferenças entre os algoritmos propostos e o *First-Fit* também mostraram-se consistentes, pois em nenhum ponto de carga o resultado é inferior ao desempenho do *First-Fit*. Na Figura 16 (b), para uma carga de 280 Erlangs e $k = 2$ o ganho em relação ao *First-Fit* foi de 57,96% e 62,13% para os algoritmos MSCL Sequencial e Combinado, respectivamente. Analisando $k = 3$, o Sequencial apresentou 62,67% de ganho, enquanto o Combinado 71,72%.

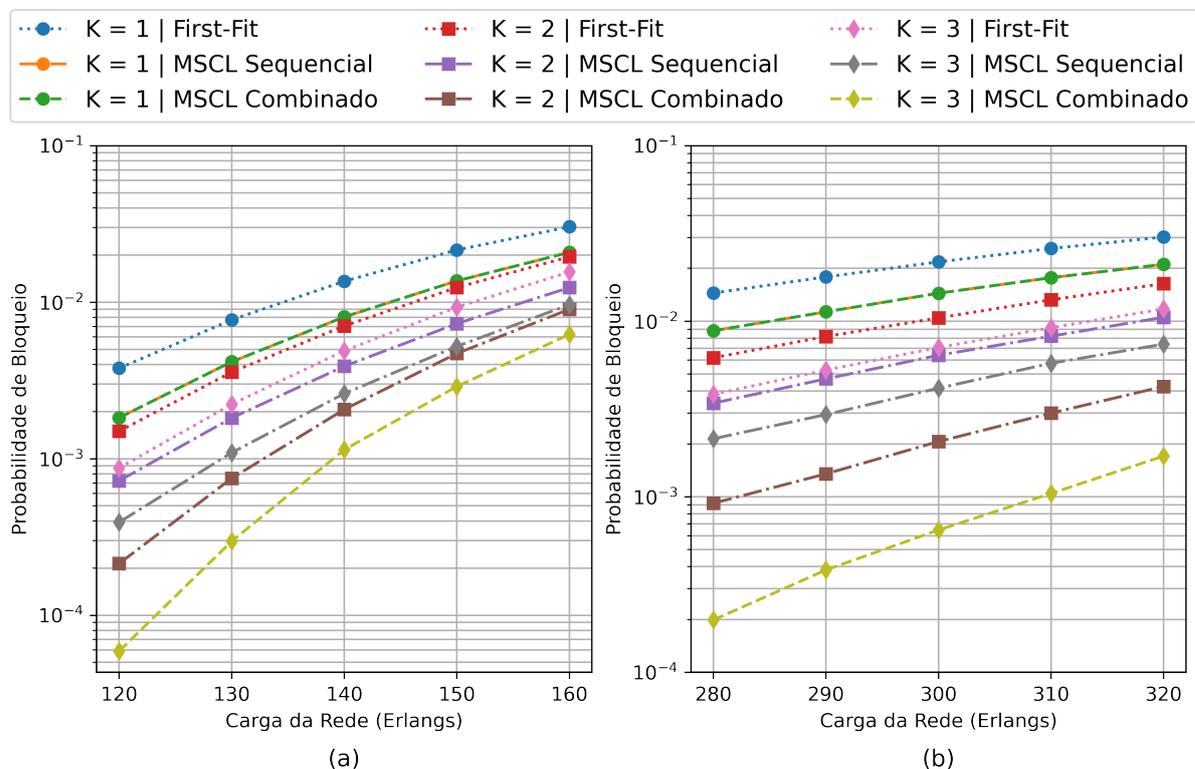
Figura 16 – Topologia Finlândia: (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir da menor ocupação WDM.



Fonte: Elaborado pelo Autor (2021).

Os desempenhos das heurísticas propostas em termos da probabilidade de bloqueio para a topologia Abilene de 11 nós e USANet de 24 nós são mostrados nas Figuras 17 (a) e (b), respectivamente. Os valores foram obtidos utilizando o conjunto de k rotas encontradas pelo algoritmo de roteamento a partir do menor número de enlace. Em todas as topologias aqui simuladas as ordens dos desempenhos mantiveram-se constantes para todos os valores de k , sendo a ordem de desempenho formada pelas heurísticas *First-Fit*, MSCL Sequencial e MSCL Combinado, do pior ao melhor, respectivamente. Com isso, conclui-se que esses resultados podem se manter para diferentes topologias.

Figura 17 – Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir do menor número de enlaces; (a) Topologia Abilene; (b) Topologia USANet.



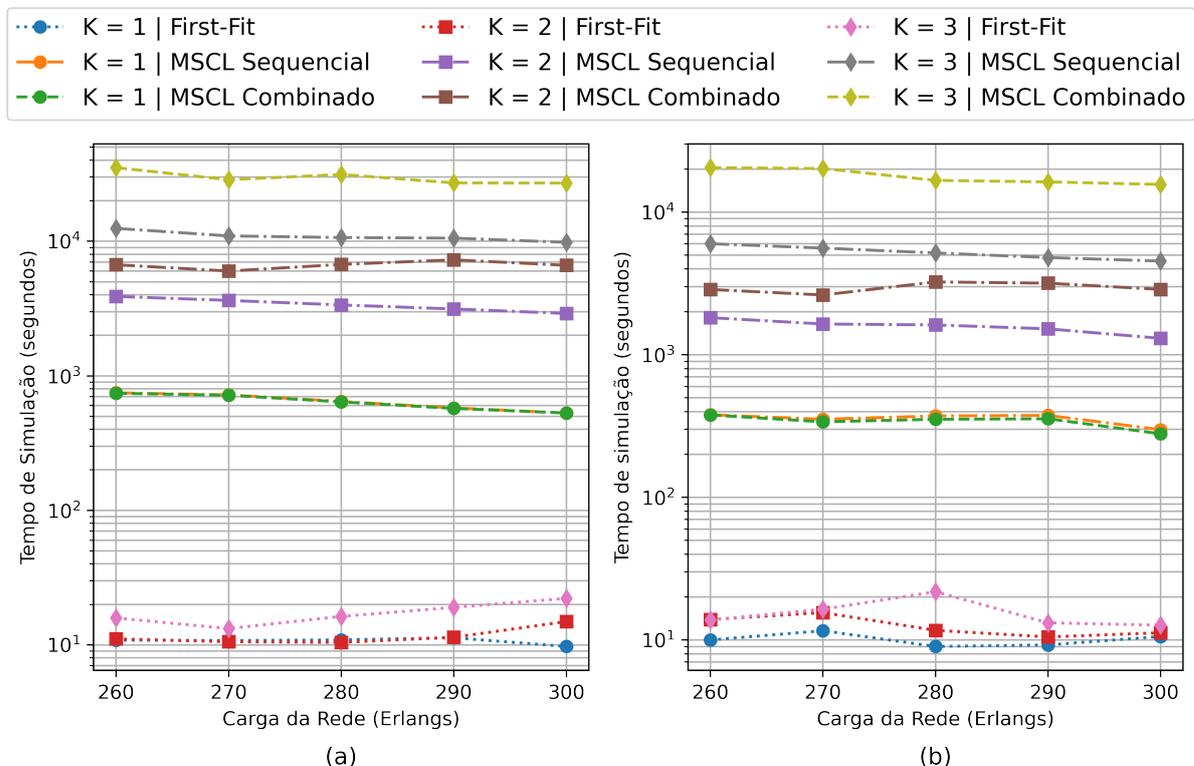
Fonte: Elaborado pelo Autor (2021).

A Figura 18 (a) mostra o tempo de execução para simular as curvas mostrada na Figura 15 (a). Conforme o valor de K aumenta, há um aumento da complexidade computacional. Um K elevado implica em mais rotas a serem analisadas, como também pelo maior conjunto de rotas interferentes a cada rota analisada. O somatório da equação de perda de capacidade percorre todo o conjunto, de modo a obter o valor da perda de capacidade na rota principal e suas interferências. Sendo assim, é possível notar o tempo de execução aumentando em ordens de grandeza para os algoritmos MSCL. Em contraponto, um valor de K elevado permite que

o algoritmo MSCL Combinado analise uma maior diversidade de combinações rota/lacuna, podendo tomar a decisão de alocar em uma rota mais longa, porém com menor perda de capacidade, caso ela assim apresente.

A Figura 18 (b) mostra o tempo de execução para simular as curvas mostradas na Figura 16 (a). De forma semelhante ao ocorrido com as probabilidades de bloqueio, o tempo de simulação permaneceu na mesma ordem em ambas as topologias. Foi observado também durante a pesquisa que rotas menores em número de enlaces apresentam menos rotas interferentes. A equação de perda de capacidade define um somatório em termos do conjunto interferente, ou seja, comparar cálculos de perda de capacidade em conjuntos interferentes com diferentes números de rotas acaba por não ser totalmente justo. Contudo, as menores tendem a ser mais escolhidas de forma que seu papel é cumprido. Esse critério de comparação merece ser estudado em trabalhos futuros. A topologia NSFNet possui mais nós e mais enlaces quando comparada à Finlândia, com isso, o tempo de simulação foi mais elevado quando analisado os mesmos algoritmos.

Figura 18 – Comparativo entre os tempos de simulação para as heurísticas apresentadas. (a) Topologia NSFNet; (b) Topologia Finlândia.



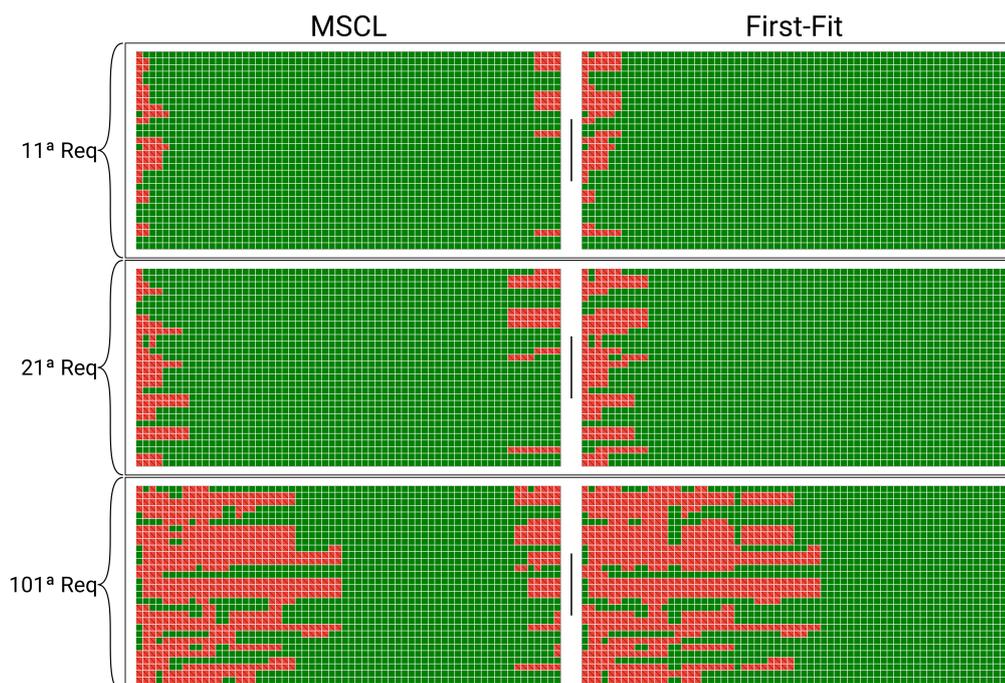
Fonte: Elaborado pelo Autor (2021).

Uma das vantagens que justificam a melhora expressiva das heurísticas MSCL em relação

ao *First-Fit* é a compactação do espectro, conforme detalhado nos trabalhos aqui relacionados. A compactação do espectro é de extrema importância para reduzir a fragmentação do espectro, e por consequência, aumentar a capacidade da rede. Usando a topologia mostrada na Figura 3, foi possível visualizar o comportamento das heurísticas durante o processo de simulação. A escolha dessa topologia foi realizada por ser uma rede em malha que contém 6 nós. Usando essa topologia em conjunto com o algoritmo de roteamento Yen-MH buscando uma única rota por par O-D ($k = 1$), há um total de 30 rotas para essa rede.

Na Figura 19 estão representados os estados do espectro na rede após alocadas a 11.^a, 21.^a e 101.^a requisição. Visualizando os retângulos como uma matriz de quadrados, as linhas representam as 30 rotas encontradas pelo algoritmo de roteamento. Nas colunas, são mostrados os estados de ocupação do espectro nestas rotas. Em vermelho tracejado os *slots* ocupados e em verde os disponíveis. Nos retângulos posicionados à direita é mostrado o estado da rede utilizando o algoritmo *First-Fit*. Seguindo a política da heurística, as requisições são compactadas à esquerda do espectro, à medida que seja possível realizar a alocação. Nos retângulos à esquerda é representada a ocupação da rede usando a heurística MSCL. Para evitar reduzir a perda de capacidade o algoritmo aloca as requisições em posições estratégicas, sendo melhor observado ao realizar as alocações ao final do espectro reduzindo assim a formação de lacunas. Essa vantagem se estende para valores de K maiores que 1.

Figura 19 – Visualização da alocação do espectro entre as heurísticas MSCL e First-Fit.



Fonte: Elaborado pelo Autor (2021).

3.4.1 Resultados com Camada Física

No artigo Santos, Almeida-Jr. e Araújo (2021) as heurísticas MSCL Sequencial e MSCL Combinado foram apresentadas considerando os impactos da camada física, como o ruído ASE (do inglês, *Amplified Spontaneous Emission*) e ganho no amplificador óptico. A Tabela 2 apresenta os parâmetros utilizados pelo simulador. Para cada simulação foram utilizadas 10^5 requisições, com tráfego de chegada assumindo um modelo *Poissoniano* e com duração das requisições distribuídas exponencialmente. Foram considerados os seguintes formatos de modulação: 4, 8, 16, 32 e 64-QAM, com SNR de 6,8, 8,6, 10,5, 12,6 e 14,8, respectivamente.

Tabela 2 – Parâmetros de configuração do simulador para utilização com camada física.

Descrição	Valor
Quantidade de <i>slot</i> por enlace	64
Número de requisições solicitadas	10^5
Polarização	1
Espaçamento de frequência do <i>slot</i> (Gb/s)	12,5
Duração média da chamada	1
Modulações	4, 8, 16, 32 e 64-QAM

Fonte: Autor.

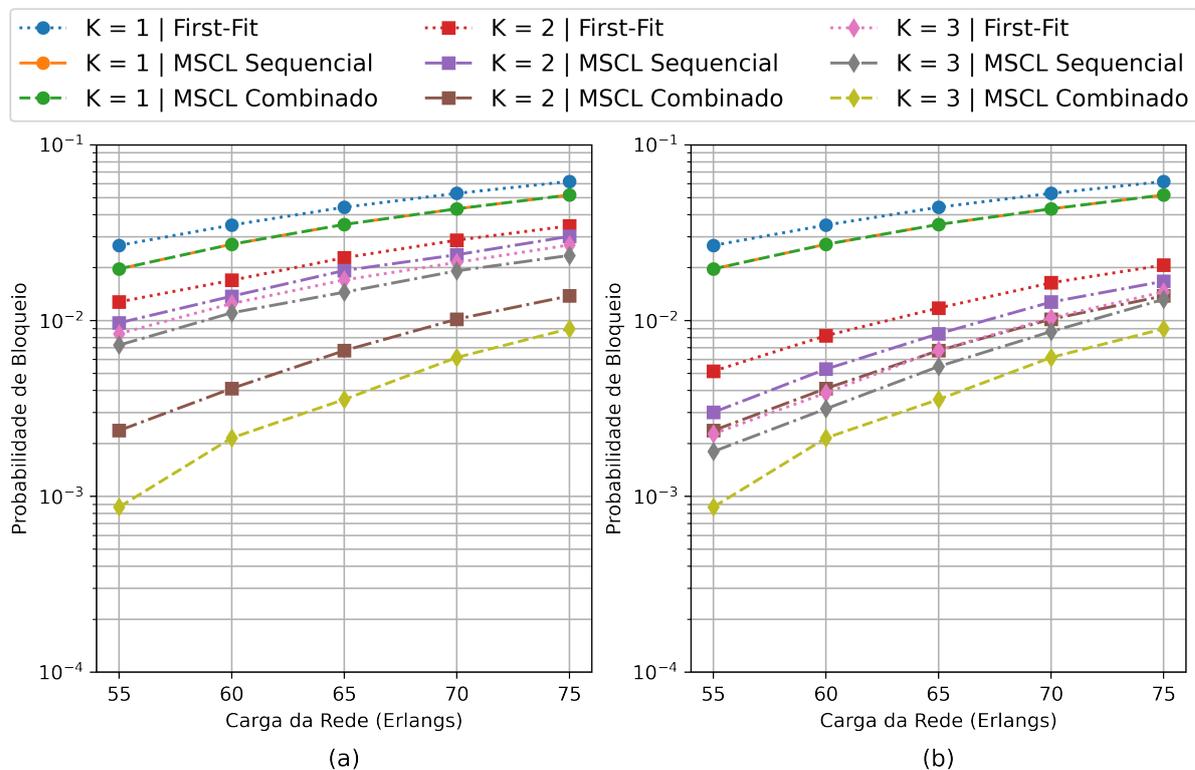
São considerados enlaces bidirecionais para as topologias simuladas, e os nós de origem e destino das requisições são escolhidos a partir de uma função de densidade de probabilidade Uniforme, assim como a taxa de transmissão sorteada por requisição. Essa taxa assume os seguintes valores: 50, 75, 100, 200 e 300 Gbits/s. Foram adotados 64 *slots* em cada enlace da topologia. Para o roteamento, foi escolhido o algoritmo Yen (1971) para encontrar as K menores rotas com base na métrica de distância.

Antes do início das simulações é calculada a quantidade de *slots* necessária para atender as taxas de transmissão, utilizando para isso a modulação com a maior eficiência espectral possível. Os valores obtidos são armazenados na estrutura das respectivas rotas e utilizados no cálculo da perda de capacidade, ou seja, cada rota principal terá sua demanda analisada para todo o espectro e em todo o seu conjunto de rotas interferentes.

A Figura 20 apresenta os resultados obtidos para os parâmetros da Tabela 2. As curvas de probabilidade de bloqueio apresentam semelhanças com os resultados obtidos sem a camada física, sendo possível concluir que as heurísticas propostas apresentam um bom funcionamento, com e sem a utilização de camada física. A utilização de camada física prejudica o MSCL

Combinado em escolher rotas mais longas, visto que nessas rotas a demanda dos *slots* é maior por consequência do uso de modulações com baixa eficiência espectral. Ainda assim, os resultados se mostraram consistentes com os obtidos sem a utilização de camada física, mantendo a melhoria para o *First-Fit* em todos os pontos de carga simulados. Diferente dessa dissertação, não houve a inversão do desempenho mostrado entre as heurísticas apresentadas para $k = 2$, sendo assim, a ordem de desempenho considerando a probabilidade de bloqueio foi: *First-Fit*, MSCL Sequencial e MSCL Combinado, do pior ao melhor, respectivamente.

Figura 20 – Topologia Finlândia usando camada física: (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir do menor número de enlaces; (b) Comparativo entre a probabilidade de bloqueio *versus* carga da rede para K rotas ordenadas a partir da menor ocupação WDM.



Fonte: Elaborado pelo Autor (2021). Adaptado de Santos, Almeida-Jr. e Araújo (2021).

4 OTIMIZAÇÃO DAS HEURÍSTICAS

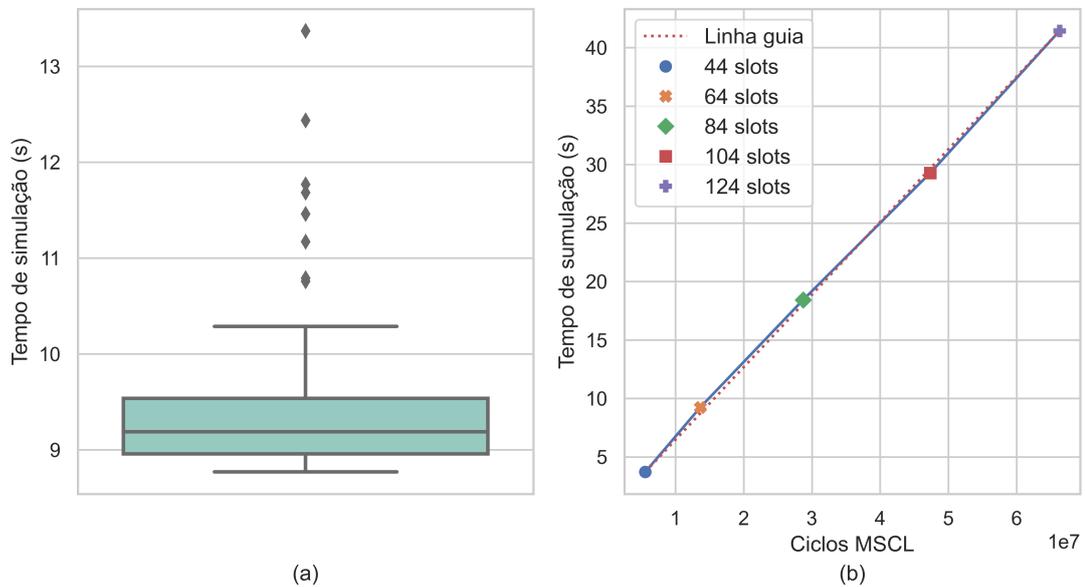
Conforme observa-se no Capítulo 3, as heurísticas propostas demonstraram expressiva melhoria quando comparadas ao *First-Fit*, entretanto, o tempo de simulação necessário para se obter os resultados é ordens de grandeza mais elevado. Sabendo que o número de *slots* por enlace é constante para toda simulação, deve-se reduzir o número de rotas presentes nos conjuntos interferentes e assim melhorar o tempo de simulação. O cálculo da perda de capacidade em algumas dessas rotas podem não apresentar importância suficiente para causar impacto positivo na probabilidade de bloqueio, mas a sua eliminação reduzirá o tempo de simulação.

Utilizar o tempo de simulação é uma tarefa complicada quando é necessário precisão para realizar as comparações. A Figura 21 (a) demonstra a oscilação do tempo para 100 simulações, utilizando parâmetros idênticos. Desconsiderando os pontos distantes da média, os valores ficam na margem de 1 segundo de simulação. Um valor pequeno, mas que pode afetar a comparação entre as heurísticas. Sendo assim, a base de tempo é importante para conhecer o tempo total que a heurística leva para processar um conjunto de requisições, mas não deve ser usado como métrica de comparação. Dessa forma, é proposta uma nova métrica chamada Ciclos MSCL para mensurar o desempenho dos algoritmos.

A métrica Ciclos MSCL corresponde um contador, acumulando uma unidade à variável em determinado local do algoritmo. Esse local, escolhido empiricamente, foi posicionado no interior do laço de repetição das rotas interferentes, presente no algoritmo MSCL tradicional. O laço de repetição das rotas interferentes, no que lhe concerne, encontra-se presente no interior do laço de repetição que percorre todos os *slots* de frequência válidos. Como essas duas são as variáveis que mais impactam no desempenho do algoritmo, esse foi o ponto escolhido e validado através de simulações. Sendo assim, os Ciclos MSCL têm forte correlação com o tempo de simulação, conforme mostrado na Figura 21 (b). Nesta Figura, ao se modificar a quantidade de *slots* de frequência presente no espectro pode-se observar essa relação. De forma que, sempre que as mesmas configurações e sementes de geração aleatória forem utilizadas, o valor do Ciclos MSCL será idêntico.

Os Ciclos MSCL e a probabilidade de bloqueio são objetivos conflitantes, de forma que serão essas métricas adotadas na otimização. Em um cenário de um único objetivo um simples valor pode informar qual a melhor solução, entretanto, no caso de múltiplos objetivos essa

Figura 21 – (a) Distribuição do tempo de simulação após 100 repetições. (b) Ciclos MSCL em função do tempo de simulação, conforme variação do número de *slots* de frequência.



Fonte: Elaborado pelo Autor (2021).

visualização não é trivial. Cada solução das otimizações propostas retornam um valor para cada um desses objetivos, sendo necessário identificar a melhor solução a partir de uma análise conjunta.

4.1 HEURÍSTICAS DE ORDENAÇÃO

Visando reduzir o tempo das simulações foram realizados estudos heurísticos para remover algumas rotas do conjunto interferente. Com essa remoção é esperado que rotas que não fornecem tanto impacto à perda de capacidade da rede sejam eliminadas, reduzindo o tempo de simulação. Os extremos das heurísticas também serão adicionados à simulação, sendo eles: quando não há nenhuma rota no conjunto interferente e com todas as rotas presentes. As remoções são realizadas ordenando as rotas interferentes a partir de determinadas métricas, mantendo somente um valor pré-definido de rotas nesse conjunto, para cada par origem-destino. A ordenação pode ser realizada em ordem crescente e decrescente, fornecendo resultados distintos nos diferentes cenários simulados. Para cada uma das heurísticas analisadas, foram assumidos um total de 75, 50 e 25% das rotas do tamanho original do conjunto. Poder-se-ia pensar em usar um número fixo de rotas interferentes para cada par origem-destino da rede. Contudo, isso acaba igualando conjuntos que são desiguais por natureza, por exem-

plo, ao se igualar a quantidade de rotas interferentes de rotas que, originalmente, possuem conjuntos interferentes demasiadamente distintos.

A Figura 22 apresenta o significado das legendas usadas nos resultados deste capítulo. Em um conjunto interferente é atribuído um custo a cada uma das suas rotas, por exemplo, utilizar a quantidade de *slots* ocupados no seu vetor de disponibilidade. Com as rotas associadas a seus respectivos custos é realizada uma ordenação das rotas desse conjunto, que pode ser feita em ordem decrescente ou crescente associada ao prefixo “Máx.” e “Mín.”, respectivamente. Após realizada a ordenação serão desconsideradas no cálculo da perda de capacidade aquelas que ficarem fora da porcentagem estabelecida. O conjunto interferente formado por “Todas as Rotas” é a forma tradicional de calcular a perda de capacidade, já a heurística “Nenhuma Rota” somente utiliza a rota principal no cálculo da perda de capacidade, desconsiderando todas as suas rotas interferentes.

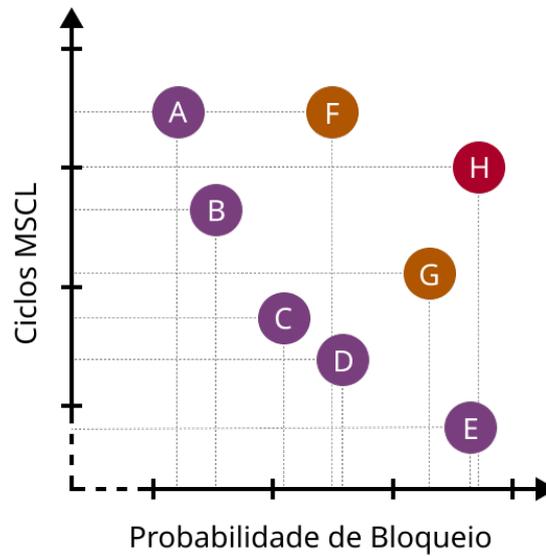
Figura 22 – Exemplos das nomenclaturas das heurísticas de ordenação. Exemplo de custo pela métrica de ocupação.

Todas as Rotas	Nenhuma Rota	25% Máx. Ocupação	50% Máx. Ocupação	50% Mín. Ocupação
Rota 1 Custo 10	Rota 1 Custo 10	Rota 2 Custo 42	Rota 2 Custo 42	Rota 4 Custo 7
Rota 2 Custo 42	Rota 2 Custo 42	Rota 3 Custo 35	Rota 3 Custo 35	Rota 1 Custo 10
Rota 3 Custo 35	Rota 3 Custo 35	Rota 1 Custo 10	Rota 1 Custo 10	Rota 3 Custo 35
Rota 4 Custo 7	Rota 4 Custo 7	Rota 4 Custo 7	Rota 4 Custo 7	Rota 2 Custo 42

Fonte: Elaborado pelo Autor (2021).

A visualização conjunta das duas métricas de desempenho será realizada utilizando uma frente de Pareto (LUO et al., 2008), sendo o eixo horizontal composto pela probabilidade de bloqueio normalizada e o eixo vertical pelos Ciclos MSCL normalizados. Na Figura 23, as soluções *A, B, C, D* e *E* representam escolhas diferentes para solucionar o problema e são preferíveis às soluções *F, G* e *H*, pois o primeiro grupo fornece vantagens em um ou mais objetivos. Na terminologia de Pareto (COELLO et al., 2007), as soluções *A* e *E* dominam as soluções *F* e *G* ou $\{A, B, C, D, E\} \preceq \{F, G\} \preceq \{H\}$. Ao comparar as soluções *A* e *E* não é possível decidir qual é a melhor solução. Por exemplo, a solução *A* apresenta uma melhor probabilidade de bloqueio, mas os Ciclos MSCL na solução *E* é menor. Sendo assim, as soluções *A* e *E* são incomparáveis entre si e estão presente no mesmo conjunto de soluções não-dominadas conhecido como uma frente de Pareto (ARAÚJO, 2015).

Figura 23 – Exemplo de soluções do problema MSCL em uma frente de Pareto.



Fonte: Elaborado pelo Autor (2021). Adaptado de ARAÚJO (2015).

A primeira métrica abordada foi a ordenação pelo número de enlace das rotas, observando o benefício de priorizar as rotas maiores ou menores dos conjuntos. A partir dos resultados obtidos, uma segunda análise foi iniciada observando o impacto das rotas predominantes e não-predominantes. O conceito de rotas predominantes tem semelhança com conjuntos matemáticos. Uma rota é dita predominante quando sua estrutura não está contida na estrutura de outra rota. As rotas contidas em outras são chamadas não-predominantes. Toda essa análise pode ser feita de forma *offline* após a criação do conjunto interferente. A Figura 24 mostra um exemplo de um conjunto interferente dividido entre rotas predominantes e as não-predominantes, mostradas na cor azul e amarelo, respectivamente. Sendo assim, o conjunto predominante e o não-predominante são a segunda e a terceira métrica, respectivamente. A quarta métrica ordena as rotas seguindo a ocupação dos *slots* de frequência. A lógica para obter a ocupação em cada rota está descrita no Apêndice A.

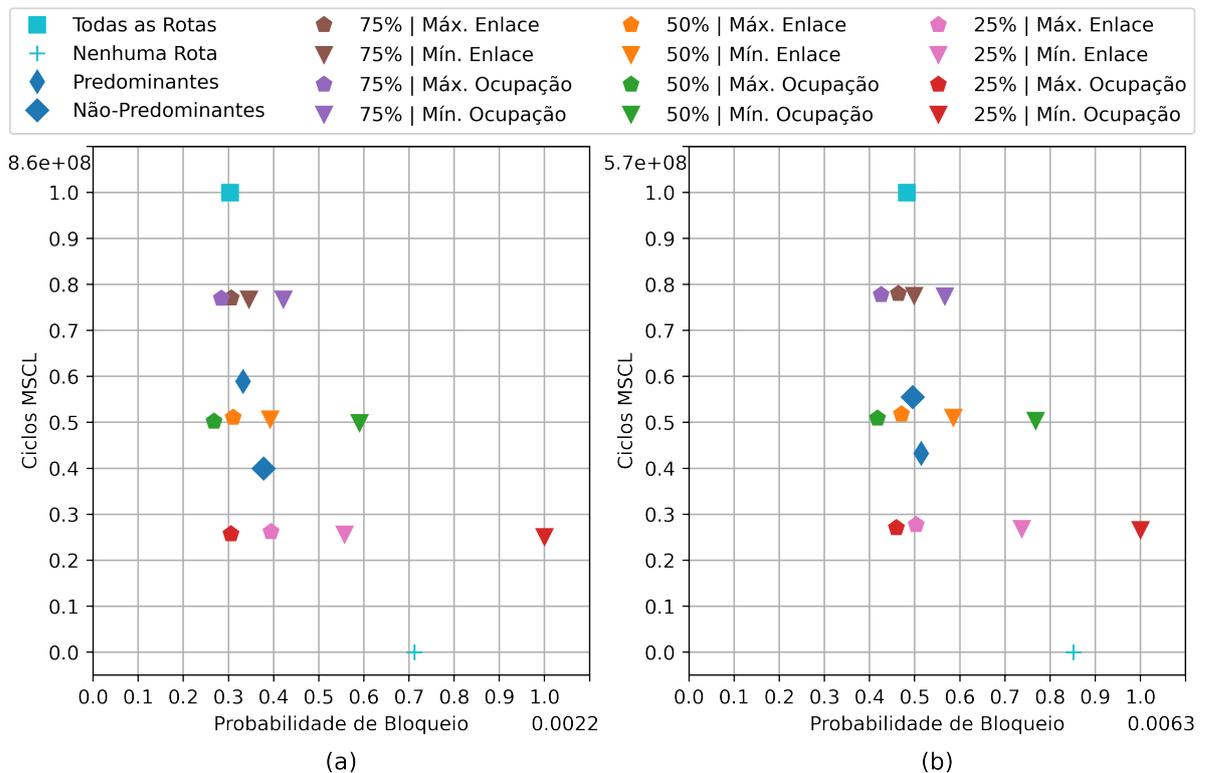
Figura 24 – Exemplo dos conjuntos predominantes e não-predominantes.

0→1→2→4	2→4	3→4→5→0	4→5
1→2→4	2→4→5	3→4→5	1→5→0
2→4→5→1	3→2→4	4→5→0	5→0
2→4→3	5→1→2→4	4→5→1	5→0→1
	Predominantes	Não-predominantes	

Fonte: Elaborado pelo Autor (2021).

As heurísticas foram simuladas para 6 cenários distintos, considerando as topologias NSF-Net e Finlândia. A Figura 25 apresenta os resultados para valores de $k = 1$ à carga de 200 Erlangs. A Figura 25 (a) apresenta os resultados para a topologia NSFNet, enquanto a Figura 25 (b) os resultados de cada uma das heurísticas para a topologia Finlândia. Esse padrão será mantido para os resultados no decorrer deste capítulo. Os valores de Ciclos MSCL e Probabilidade de Bloqueio foram normalizados dividindo os resultados pelo maior valor encontrado.

Figura 25 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 1$ à carga de 200 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.



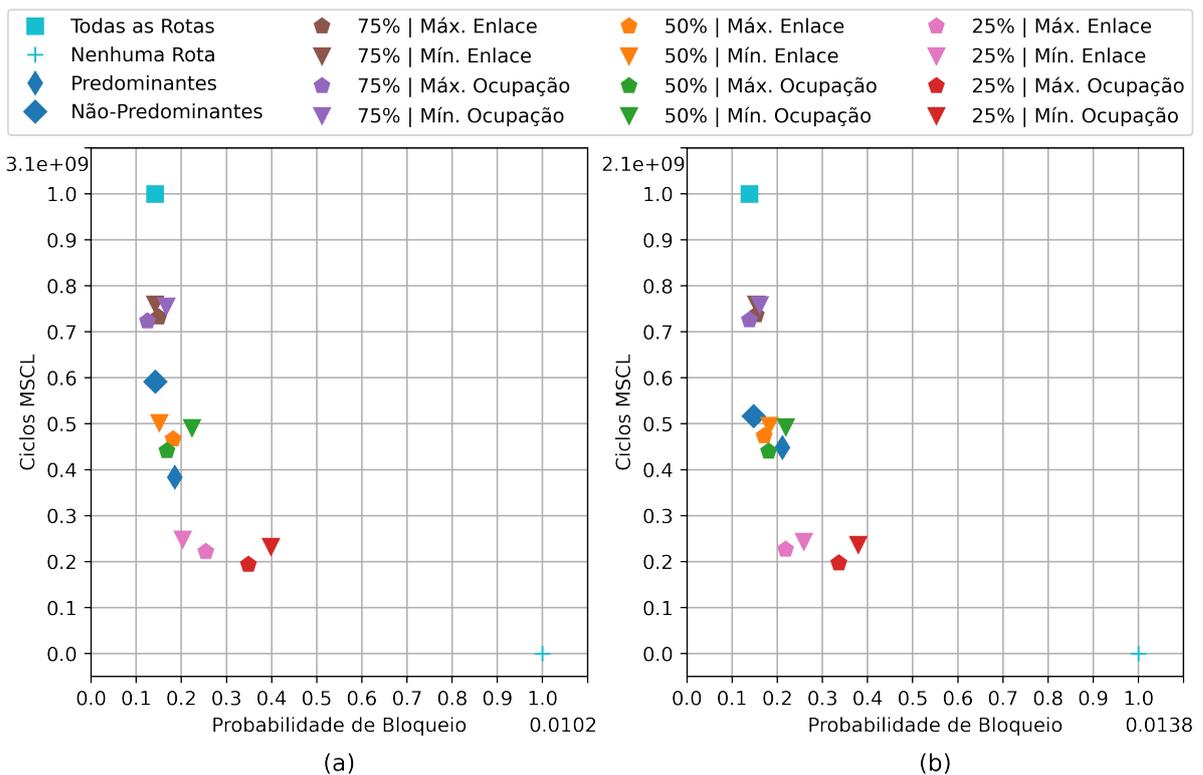
Fonte: Elaborado pelo Autor (2021).

A heurística representada pelo quadrado azul-turquesa é a forma tradicional de utilizar a heurística MSCL, em que, todas as rotas do conjunto interferente são utilizadas no cálculo da perda de capacidade, de acordo com a Equação 2.3. Sendo assim, essa é a referência a ser melhorada. Caso exista uma heurística de ordenação que apresente ao menos um tempo de execução menor ela já será preferida. Era esperado que o MSCL com nenhuma rota interferente (ou seja, conjunto interferente vazio na Equação 2.3) apresentasse o pior desempenho na probabilidade de bloqueio, mas ele foi superado pela heurística de menor ocupação usando 25% do conjunto. Com isso, pode-se concluir existir rotas que prejudicam uma boa alocação do espectro. Essa conclusão pode ser validada pela heurística maior ocupação usando 50% do

conjunto, apresentando melhor resultado de probabilidade de bloqueio frente todas as outras simulações. Esse resultado de probabilidade de bloqueio economiza em torno de 50% do tempo de simulação, validada nas duas topologias simuladas.

Os resultados para um cenário que utiliza $k = 2$ à carga de 270 Erlangs é apresentado na Figura 26. Diferente do cenário com $k = 1$ as probabilidades de bloqueio ficaram próximas quando se compara a ordenação de forma crescente e decrescente. Esse fenômeno é um processo de transição, sendo seus efeitos melhores observados em $k = 3$. Enquanto em $k = 1$ deve ser priorizado a ordenação na ordem decrescente para todas as métricas, em $k = 2$ essa prioridade só deve ser adotada para a topologia Finlândia, com exceção da métrica de ocupação em 25%.

Figura 26 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 2$ à carga de 270 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.

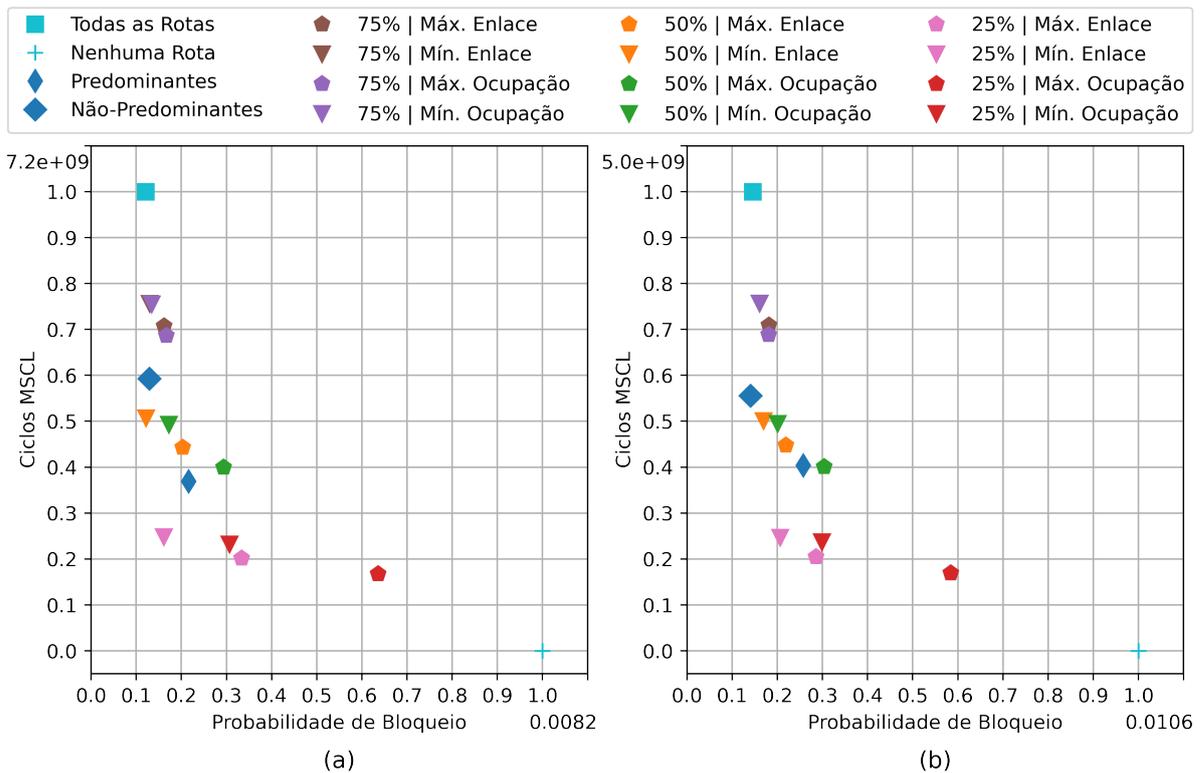


Fonte: Elaborado pelo Autor (2021).

A Figura 27 mostra os resultados na carga de 280 Erlangs e $k = 3$. Enquanto no cenário para $k = 1$ deve-se priorizar as rotas com o maior número de enlaces, em $k = 2$ há uma proximidade entre as soluções na ordem crescente e decrescente. Em $k = 3$ é demonstrada uma vantagem na probabilidade de bloqueio ao priorizar as rotas com menos enlace no conjunto interferente. A mesma observação pode ser realizada ao considerar a métrica de ocupação,

até $k = 2$ é preferível utilizar as rotas mais congestionadas no cálculo da perda de capacidade através do conjunto interferente. Em $k = 3$ as melhores probabilidades de bloqueio são obtidas ao utilizar as rotas com menor ocupação no conjunto de rotas interferentes.

Figura 27 – Frente de Pareto com métricas Ciclos MSCL e Probabilidade de Bloqueio para $k = 3$ à carga de 280 Erlangs. (a) Topologia NSFNet. (b) Topologia Finlândia.



Fonte: Elaborado pelo Autor (2021).

A inversão de desempenho entre as heurísticas com prefixo 'Mín' e 'Máx', conforme o valor de k aumenta, acontece devido a subutilização de algumas rotas. Em $k = 1$ todos os caminhos presentes no conjunto de rotas interferentes são utilizados pelos seus respectivos pares origem-destino. Devido dessa utilização, é preferível priorizar as rotas interferentes que são mais longas em número de enlace e estão mais ocupadas. Em $k = 2$ e $k = 3$, como há caminhos auxiliares para um mesmo par O-D, a prioridade é calcular a perda de capacidade nas rotas mais curtas em número de enlaces, pois normalmente essas tendem a serem mais escolhidas pelo algoritmo MSCL.

Dentre os 6 cenários simulados, utilizar o conjunto de rotas Não-Predominantes apresentou valores de probabilidade de bloqueio praticamente iguais aos do MSCL tradicional em 5 deles, usando entre 50 a 60% dos Ciclos MSCL e se mostrando uma boa heurística para reduzir o tempo de execução mantendo a probabilidade de bloqueio. Em $k = 1$ priorizar o conjunto

formado pelas rotas interferentes com a maior ocupação se mostrou uma ótima solução para melhorar a probabilidade e o tempo de simulação. Considerando a ordenação pela maior ocupação em 50%, a melhora da probabilidade de bloqueio foi de 11,90% e 13,43% ao comparar com a utilização de todas as rotas, para as topologias NSFNet e Finlândia, respectivamente. Em $k = 2$, os melhores valores de probabilidade de bloqueio são obtidos em 75% do conjunto ordenado pela maior ocupação, com 11,85% para a topologia NSFNet e com uma perda de 0,21% na topologia da Finlândia. Em $k = 3$ há uma diferença entre as heurísticas de otimização ao comparar as topologias, no entanto, as melhores soluções ficaram no intervalo de 0,5 a 0,6 Ciclos MSCL. Na topologia NSFNet a solução que se destacou foi a ordenação de mínimo enlace em 50% do conjunto interferente obtendo uma melhoria de 0,60% de probabilidade de bloqueio em relação ao MSCL padrão. Já para a topologia Finlândia e com o conjunto interferente das rotas Não-Predominantes há uma perda de 3,51%.

Na sequência desse capítulo será explicado o conceito de algoritmos evolutivos, suas características e aplicações já propostas para redes ópticas, com ênfase para uma subclasse chamada Algoritmos Genéticos Multi-objetivo. Essa contextualização visa explicar uma nova proposta de otimização na redução do tempo de simulação das heurísticas MSCL, encontrando o balanço entre a probabilidade de bloqueio e o tempo de simulação, visto que essas são métricas conflitantes.

4.2 ALGORITMOS EVOLUTIVOS

Os algoritmos evolutivos são uma sub-área da inteligência artificial, que se baseiam no comportamento de determinados animais, processos e modelos de fenômenos biológicos. Essas técnicas são comumente utilizadas na solução de problemas complexos em diversas áreas, ainda não resolvidos por outras técnicas computacionais, como os problemas de otimização. Essa categoria contemplam as técnicas de algoritmos evolucionários e inteligência de enxame (CASTRO; ZUBEN, 2005).

As técnicas de inteligência de enxame utiliza o comportamento social de grupo de animais para formar a base de inúmeros algoritmos, dentre os mais populares se destacam o PSO (do inglês, *Particle Swarm Optimization*). Proposto por Kennedy e Eberhart (1995), utiliza a inteligência do voo de um exame de pássaros para obter a solução de problemas. Esses pássaros, comumente chamados partículas, percorrem o espaço d -dimensional em busca da melhor posição. A melhor posição encontrada representa a melhor solução para o problema

proposto. As partículas cooperam e compete entre si, elas buscam chegar ao melhor local do espaço de busca e compartilham a sua posição com as outras buscando novas melhores posições. Em Dinarte et al. (2021) os autores aplicaram o PSO em uma nova proposta de roteamento e alocação do espectro, reduzindo assim a probabilidade de bloqueio.

Outra sub-classe dos algoritmos evolutivos é o chamado algoritmo genético (GA do inglês, *Genetic Algorithm*). Sua inspiração vem dos mecanismos da evolução presente no modelo Darwiniano de seleção natural e reprodução genética. De acordo com Charles Darwin, a seleção natural privilegia os indivíduos mais aptos com maior longevidade, portanto, propaga seu código genético nas futuras gerações (GOLDBERG, 1989). Os indivíduos representam as soluções candidatas ao problema de otimização, e carregam consigo uma função de avaliação que indica o quão boa essa solução é para o problema. Problemas do mundo real geralmente apresentam objetivos conflitantes que precisam ser otimizados simultaneamente, semelhante aos objetivos do MSCL mostrado no começo desse capítulo. Já foi demonstrado que o algoritmo genético chamado multi-objetivo pode ser aplicado a problemas com dois ou mais objetivos conflitantes (COELLO et al., 2007).

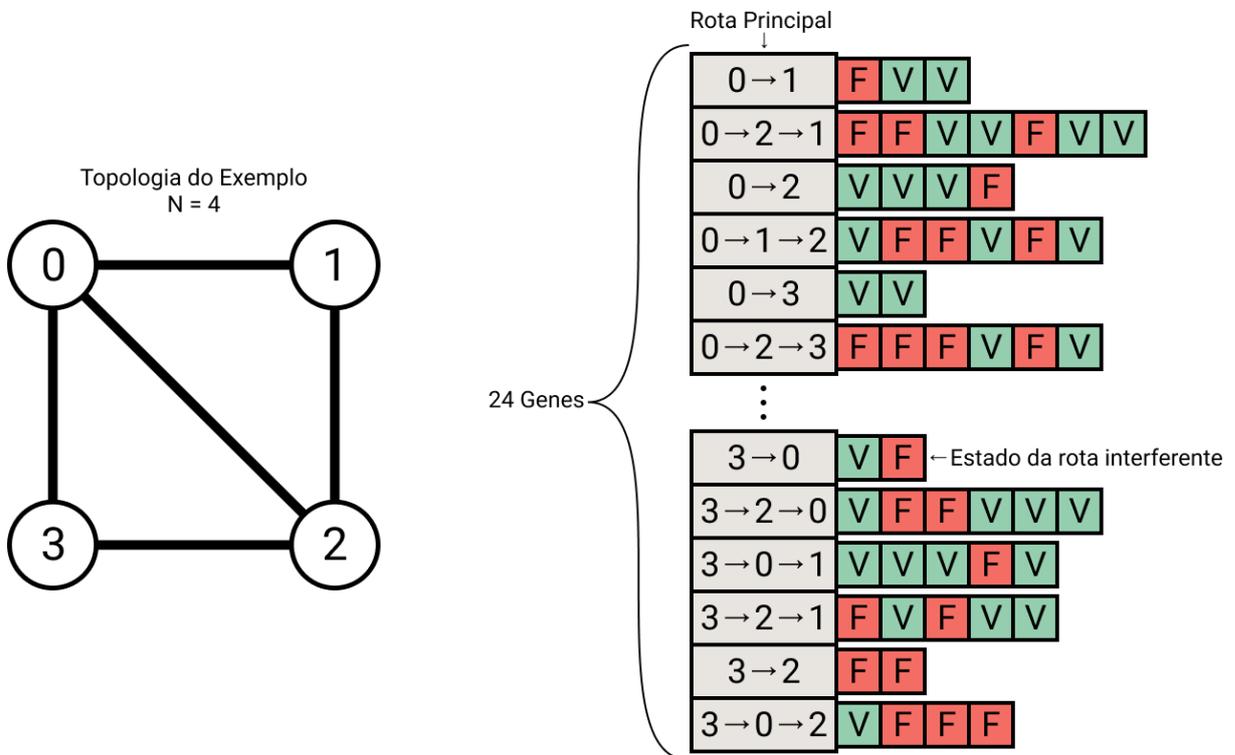
4.2.1 Otimização Multi-Objetiva

A nova proposta de otimização multiobjetivo utiliza uma estratégia inspirada no algoritmo genético multiobjetivo NSGAI (do inglês, *Non-dominated Sorting Genetic Algorithm II*). O NSGAI surgiu em Deb et al. (2002) para resolver problema com dois objetivos conflitantes, assim adotado como inspiração para o modelo desenvolvido nessa dissertação. Em Araújo et al. (2011) os autores aplicaram o NSGAI em projetos de redes ópticas, concluindo que a melhoria na qualidade das soluções advêm das adaptações realizadas nos operadores genéticos e em menor intensidade devido à meta-heurística adotada.

A nova proposta utiliza uma estratégia baseada no NSGAI para decidir quais rotas interferentes devem ser consideradas durante o cálculo da perda de capacidade. No GA desenvolvido para essa pesquisa, cada indivíduo representa um vetor de tamanho C_s , obtido pela Equação 3.2. Cada posição desse vetor é conhecido como gene, sendo representado por uma lista de tamanho variado cuja dependência é atrelada ao número de rotas interferentes a cada rota principal. A Figura 28 ilustra a representação cromossômica para o problema com $T_{node} = 4$ e $K = 2$. A lista ordenada presente em cada gene pode assumir dois estados, verdadeiro ou falso. O estado verdadeiro indica que a rota interferente de mesmo índice será considerada no

cálculo da perda de capacidade, caso contrário, essa rota será desconsiderada.

Figura 28 – Representação do indivíduo para a heurística de otimização multi-objetivo.



Fonte: Elaborado pelo Autor (2021).

Realizada a representação do cromossomo, são criados indivíduos com genes em estados aleatórios para formar uma população inicial P_i . Para evitar que em todas as soluções geradas a quantidade de rotas fosse em torno de 50% do conjunto caso os valores 0 e 1 fossem escolhidos com a mesma probabilidade, aplicou-se um limiar de decisão aleatório para cada indivíduo. É sorteado um fator de probabilidade uniforme entre 0 e 1 para cada indivíduo. Esse fator aparece como f_r na Equação 4.1 sendo usado para fixar a probabilidade da permanência P_l das rotas interferentes mantendo entre 10 a 90% do conjunto, criando indivíduos com as mais diversificadas características, dado que aleatoriedade na população inicial é de extrema importância para que as soluções geradas cubram a maior área de busca (LINDEN, 2008). Durante a criação da população inicial, podem ser adicionados indivíduos específicos com características únicas. Esses indivíduos servem para criar uma tendência na população. Para a heurística proposta, foram plantados dois indivíduos, um deles com os estados dos genes em verdadeiro e o outro com todos os genes em falso.

$$P_l = 0,1 + f_r \cdot 0,8 \quad (4.1)$$

4.2.1.1 Avaliação e Seleção dos Indivíduos

A avaliação dos indivíduos é feita por meio de simulação com o simulador de redes ópticas elásticas. Após as simulações, a probabilidade de bloqueio e os Ciclos MSCL são usados para adicionar os indivíduos a uma frente de Pareto, em que, os indivíduos situados na primeira frente de Pareto são melhores avaliados que os posicionados na segunda frente de Pareto, assim sucessivamente. A comparação entre os demais indivíduos localizados em uma mesma frente de Pareto é realizada usando uma estimativa de densidade com o método “Distância de Multidão” (CD, do inglês *Crowding Distance*). Os indivíduos de fronteira localizado ao extremo da frente de Pareto (A e E) recebem infinito para o valor do CD e os demais indivíduos são calculados baseados nas distâncias dos seus vizinhos laterais. Um valor elevado de CD indica que a solução está contida em uma região pouco densa, tornando essa solução importante para manter a diversidade genética para as próximas gerações. Indivíduos localizados em regiões pouco densas não tendem a apresentar grande variação de características e não devem ser priorizados como critério de desempate (LUO et al., 2008; ARAÚJO, 2015).

Após simular todas as soluções presentes na população inicial elas são colocadas em suas respectivas frentes de Pareto. Com isso, é calculado e armazenado o valor do *Crowding Distance* de cada indivíduo. O processo de seleção dos pais é feito pelo método de torneio, são escolhidas duas soluções competidoras. Inicialmente é observado a frente de Pareto da solução, aquela localizada na melhor frente será usada para transmitir seu material genético. Em caso de empate será usada aquela com a melhor CD. Com dois indivíduos distintos selecionados para serem os pais é realizado o processo de cruzamento.

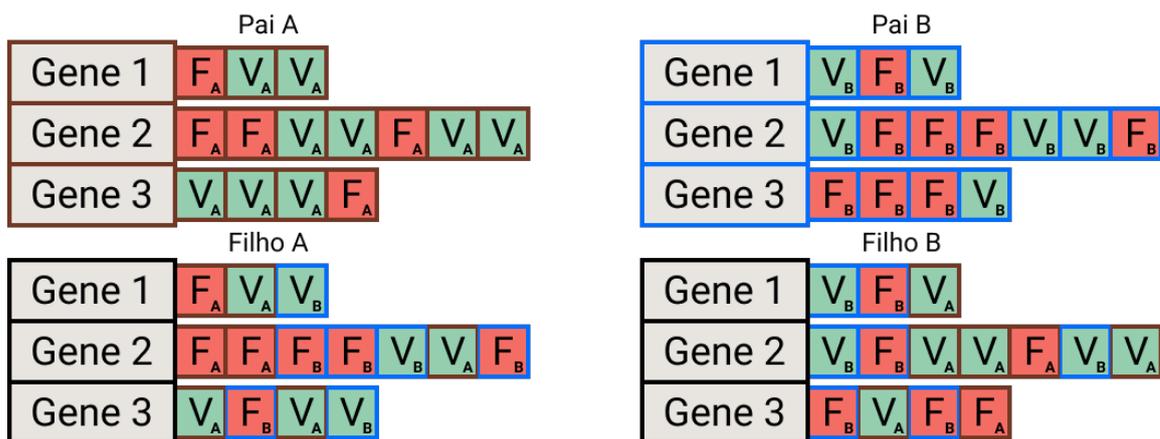
4.2.1.2 Cruzamento

O procedimento de combinar o material genético dos pais para gerar os filhos é chamado cruzamento. Esse método tem por objetivo propagar as características dos indivíduos mais bem adaptados ao ambiente. O modo como o cruzamento é realizado depende fortemente da forma como os cromossomos são representados. No algoritmo genético proposto, o procedimento utilizado aqui foi inspirado no método de cruzamento uniforme (REEVES, 2010), em que são gerados dois filhos para cada dois pais. Foram adotados dois métodos de cruzamento inspirado no método conhecido de cruzamento uniforme. O intitulado cruzamento de tipo 1 utiliza o cruzamento ao nível de sub-gene (as subdivisões do vetor que representa cada gene), enquanto

no cruzamento tipo 2 essa operação é feita nos genes. Usando esses métodos, cada sub-gene (ou gene, no b-caso de cruzamento de tipo 2) do novo indivíduo tem uma probabilidade P_h de herdar o material genético do sub-gene de mesmo índice do 'Pai A' e $1 - P_h$ para herdar do 'Pai B'.

Na Figura 29, pode-se observar um exemplo de cruzamento do tipo 1, em que os filhos carregam fragmentos do material genético dos pais obtidos de forma aleatória. Os sub-genes do 'Pai A' estão na cor marrom e marcados pela letra 'A', já o do 'Pai B' estão na cor azul e com a marcação da letra 'B'. Por exemplo, no gene 1 do 'Filho A' a herança genética dos dois primeiros sub-genes vem do 'Pai A' e a terceira é herdada do 'Pai B'. É um processo aleatório, que se segue até a completa formação dos filhos, no qual o 'Filho B' é o complemento do 'Filho A'.

Figura 29 – Exemplo de cruzamento do tipo 1 para a representação do cromossomo utilizado.



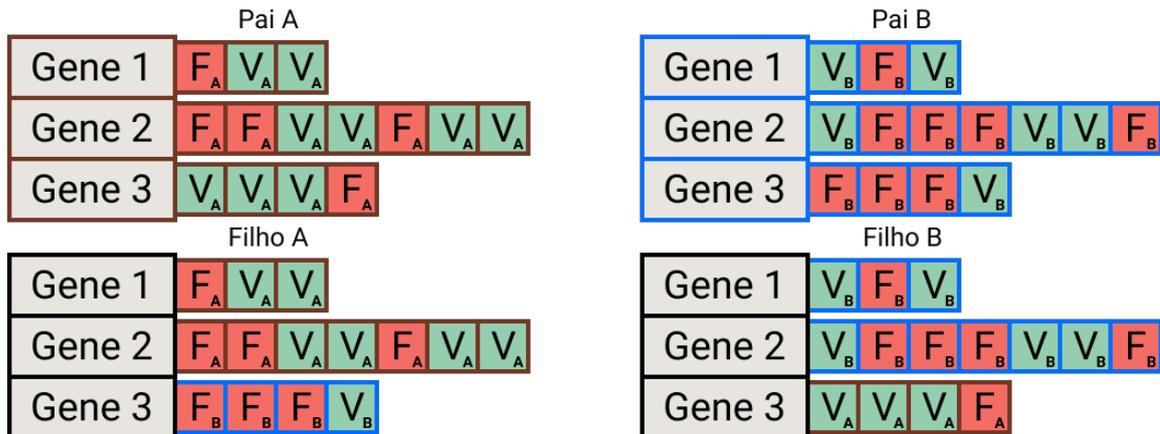
Fonte: Elaborado pelo Autor (2021).

A Figura 30 demonstra um exemplo de cruzamento do tipo 2, seguindo o diagrama de cores mostrado acima. Neste cruzamento a probabilidade P_h é usada para transmitir todo o gene do 'Pai A' para o 'Filho A' e $1 - P_h$ para o 'Filho B', como é exemplificado pelo gene 3 na Figura. O cruzamento do tipo 2 é menos agressivo o tipo 1, no enteando, ambos apresentaram resultados satisfatórios ao problema.

4.2.1.3 Mutação

O processo de mutação genética presente na natureza é característico de uma falha durante o processo de clonagem na criação de novos indivíduos. Esse operador genético é reproduzido em algoritmos genéticos para manter a diversidade genética de uma geração para a próxima.

Figura 30 – Exemplo de cruzamento do tipo 2 para a representação do cromossomo utilizado.

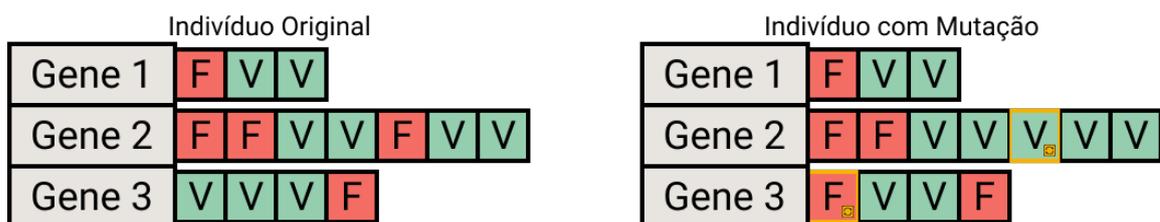


Fonte: Elaborado pelo Autor (2021).

O processo de mutação altera um ou mais genes do cromossomo do indivíduo selecionado, obtendo assim uma nova solução para o problema. A alteração genética segue uma probabilidade P_m que deve ser definida como baixa. Se a probabilidade for elevada, o processo evolutivo torna-se aleatório, prejudicando assim a convergência de toda a população. Operadores de mutação são muitas vezes usados na tentativa de evitar mínimos locais, evitando que a população de cromossomo se torne muito semelhante ao passar das gerações (HOLLAND et al., 1992). O método adotado para realizar a mutação na representação proposta é conhecido como *Flip Bit*. O estado do sub-gene será invertido para o seu oposto sempre que for determinado pela probabilidade P_m .

A Figura 31 mostra um exemplo de mutação aplicado a representação cromossômica adotada. É possível observar a inversão de dois sub-genes do gene 2 e 3 copiados do indivíduo original, marcado em amarelo no indivíduo com mutação. A probabilidade de mutação P_m é aplicada a todos os sub-genes, aqueles que ficarem abaixo do valor estabelecido sofrerá mutação. Em um cenário hipotético onde existam 200 sub-genes, quando aplicada uma probabilidade de mutação em 1% haverá uma média de 2 sub-genes afetados pela mutação.

Figura 31 – Exemplo de mutação para a representação do cromossomo utilizado.

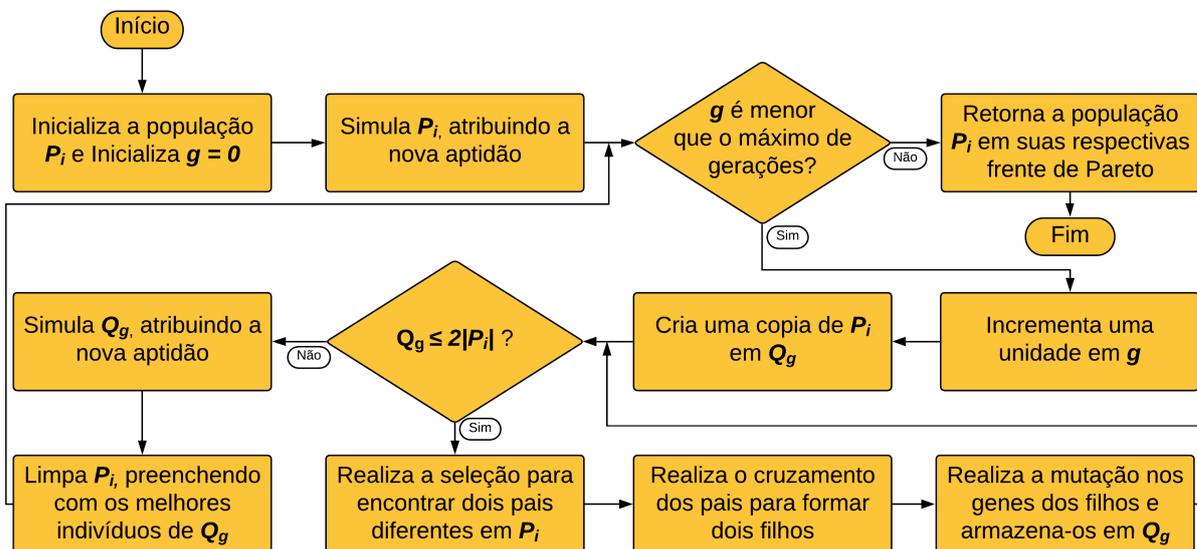


Fonte: Elaborado pelo Autor (2021).

4.2.1.4 Estrutura do Algoritmo Genético Multi-Objetivo

O procedimento de execução do algoritmo genético inspirado no NSGAI1 realiza os operadores de seleção dos pais, cruzamento e mutação em repetição. A quantidade de repetições é definida em metade do número de indivíduos da população inicial $\frac{|P_i|}{2}$, obtendo ao final das repetições $|P_i|$ filhos que são adicionados a uma nova população Q_g . Essa nova população contém duas vezes o tamanho da população inicial ($|Q_g| = 2|P_i|$), em que $|X|$ representa o número de elementos em X . Realizado esse procedimento toda a população Q_g é simulada para avaliar o desempenho de cada solução. Caso um mesmo indivíduo seja simulado mais que uma vez, até o total de I_m vezes, é retirada uma média dos resultados obtidos entre as simulações. Usando os novos resultados de probabilidade de bloqueio e Ciclos MSCL as soluções são colocadas em suas respectivas frente de Pareto. A seleção dos indivíduos que permanecerão para a próxima geração é feita com base na frente de Pareto e do *Crowding Distance*, selecionando os $|P_i|$ melhores indivíduos. A Figura 32 apresenta um fluxograma para o funcionamento do NSGAI1 adotado.

Figura 32 – Fluxograma do funcionamento do algoritmo genético.



Fonte: Elaborado pelo Autor (2021).

A Tabela 3 mostra os parâmetros de configurações adotado para o algoritmo genético durante o processo de simulação dos resultados. Esses valores foram obtidos de forma empírica com base em testes utilizando valores comuns encontrados na literatura. Devido a grande quantidade de sub-genes para as topologias simuladas, o valor de 1% de mutação foi utilizado para garantir que a diversidade genética seja mantida, sem prejudicar a convergência do algo-

ritmo. A probabilidade de herança P_h em 50% representa que a formação de um filho herdará, em média, metade do material genéticos dos pais. A probabilidade P_c em 100% indica que sempre que selecionados dois pais, serão gerados dois filhos.

Tabela 3 – Parâmetros de configuração para o algoritmo genético.

Símbolo	Descrição	Valor
P_m	Probabilidade de mutação do sub-gene	1%
P_c	Probabilidade de cruzamento	100%
P_h	Probabilidade de herança	50%
$ P_i $	Tamanho inicial da população	40
I_m	Número máximo de simulação para um indivíduo	5
g_{max}	Número máximo de gerações	500

Fonte: Autor.

4.3 COMPARAÇÃO DOS RESULTADOS

Os algoritmos genéticos são uma ferramenta conhecida para resolver problemas com alto grau de complexidade, entretanto, dada a sua natureza de simular diversas soluções, faz-se necessário que o tempo de execução de uma solução seja relativamente baixo. A Equação 4.2 determina o tempo final que o algoritmo genético levará para finalizar as simulações.

$$t_f = (t_s \cdot g_{max} \cdot 2 |P_i|) + (t_s \cdot |P_i|), \quad (4.2)$$

em que, t_s é o tempo que dura uma única simulação; t_f é o tempo final após g_{max} gerações com uma população de $|P_i|$ indivíduos.

Após realizar milhares de simulações, o tempo necessário para se obter uma convergência pode ficar demasiadamente elevado. Utilizando as configurações apresentadas, analisando que o pior cenário demanda 1104 segundos, considera-se o tempo médio de simulação dos indivíduos da população em 400 segundos. Usando esse valor, o tempo total de simulação poderia chegar em cerca de 180 dias. Por ser um valor infactível considerando o cronograma desta pesquisa, optou-se por reduzir os parâmetros de simulação para que a pior solução dure no máximo 40 segundos e obtenha a convergência após alguns dias. A Tabela 4 apresenta as novas configurações utilizadas para obter uma probabilidade de bloqueio em 10^{-3} , com as cargas de 80 e 90 Erlangs para as topologias da Finlândia e NSFNet, respectivamente.

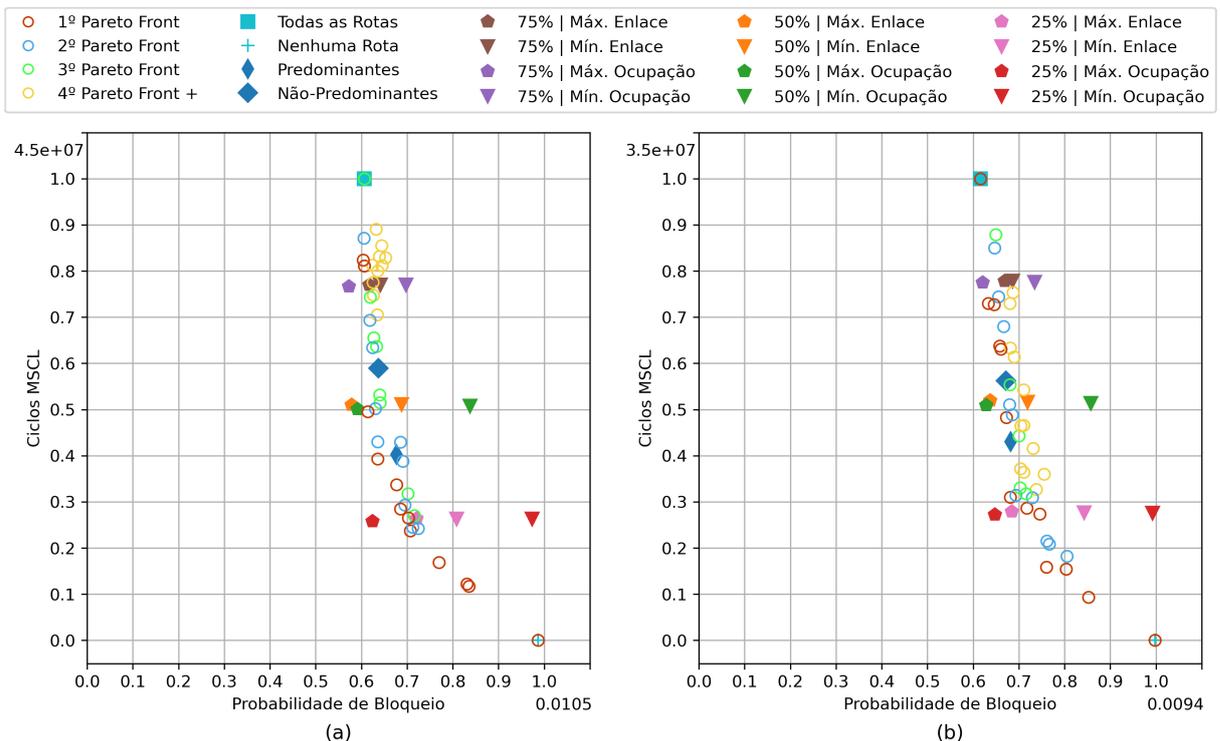
Tabela 4 – Parâmetros de configuração do simulador para o algoritmo genético.

Descrição	Valor
Quantidade de <i>slot</i> por enlace	64
Número de requisições solicitadas	10^5

Fonte: Autor.

A Figura 33 apresenta as novas simulações para as heurísticas mostradas anteriormente neste capítulo, considerando $k = 1$ e os parâmetros mostrados na Tabela 3. Seguindo o padrão adotado, a Figura 33 (a) representa a topologia NSFNet, enquanto a Figura 33 (b) a topologia Finlândia. Sobre as marcações das heurísticas foram adicionadas as frentes de Pareto, numeradas de 1 a 3. A primeira frente de Pareto é representada pela cor vermelha, a segunda na cor azul e a terceira na cor verde. As demais frentes de Pareto são mostradas na cor amarelo e todas elas são representadas por um círculo vazado.

Figura 33 – Frentes de Pareto para o algoritmo genético. População inicial de indivíduos. (a) Topologia NSF-Net. (b) Topologia Finlândia.



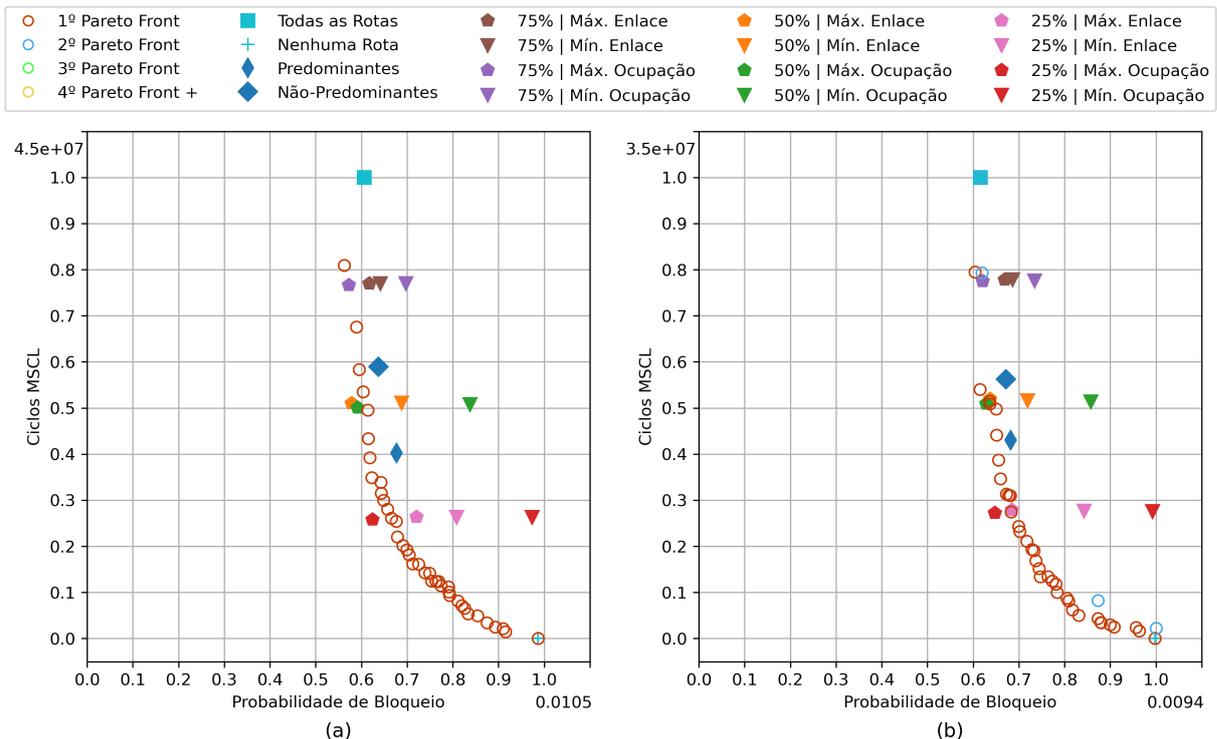
Fonte: Elaborado pelo Autor (2021).

Os indivíduos mostrados na Figura 33 correspondem a população inicial criada de forma aleatória, com a solução “Todas as rotas” e “Nenhuma rota” implantados na população. Cabe ressaltar que para a topologia NSFNet, o processo de criação dos indivíduos iniciais já retornou uma solução melhor que modelo base do MSCL, usando todas as rotas. É possível fazer essa

observação analisando que a solução “Todas as Rotas”, representada pelo quadrado azul, não está presente na primeira frente de Pareto. Na topologia Finlândia essa solução inicia na primeira frente de Pareto, e permanece nela até a geração 34. Outra observação relevante é que a maioria das soluções iniciais já se destacam, ao comparar com as heurísticas que realizam a ordenação através da mínima ocupação e das rotas mais curtas.

A Figura 34 mostra os resultados para a população de indivíduos (P_i) após 50 gerações usando o operador de cruzamento tipo 1. Na topologia NSFNet todos os indivíduos em P_i pertencem à primeira frente de Pareto. A solução posicionada próximo a 0,8 Ciclos MSCL se sobressai a todas as outras heurísticas em probabilidade de bloqueio. As demais soluções seguem distribuídas abaixo desse valor. Na topologia Finlândia, 3 soluções estão presentes na segunda frente de Pareto. Com exceção da melhor solução em PB próximo a 0,8 Ciclos MSCL as demais soluções estão aglomeradas abaixo de 0,55 Ciclos.

Figura 34 – Frentes de Pareto para o algoritmo genético. População de indivíduos após 50 gerações com cruzamento do tipo 1. (a) Topologia NSFNet. (b) Topologia Finlândia.

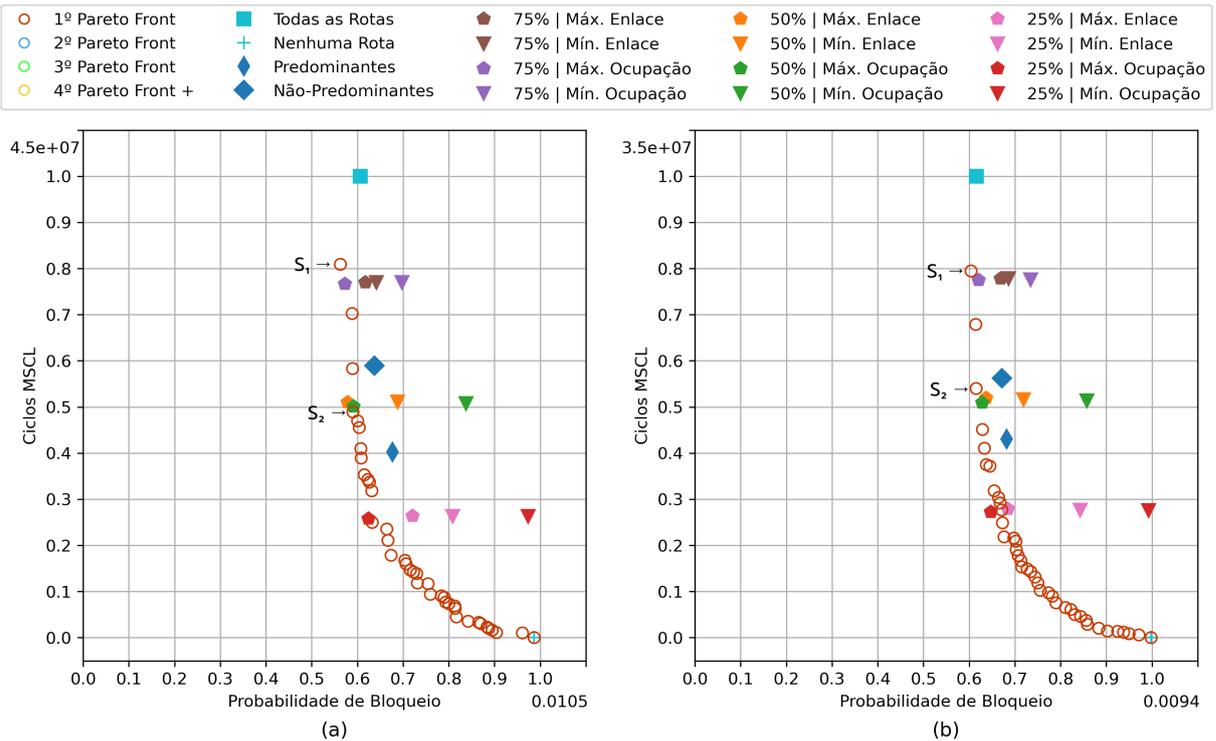


Fonte: Elaborado pelo Autor (2021).

A condição de parada do algoritmo genético foi definida em 500 gerações. Os indivíduos que chegaram nessa população usando o operador de cruzamento tipo 1 são mostrados na Figura 35. Duas soluções se destacam entre as demais, marcadas de S_1 e S_2 no gráfico. O destaque dessas soluções se deve a uma melhoria na probabilidade de bloqueio, quando comparada com

o MSCL padrão (“Todas as Rotas”), ou um valor próximo usando menos Ciclos MSCL. Os indivíduos indicados por S_1 nas figuras são as melhores soluções em probabilidade de bloqueio, no entanto, são as soluções que mais demandam tempo de execução dentre as novas heurísticas encontradas.

Figura 35 – Frentes de Pareto para o algoritmo genético com cruzamento do tipo 1. População de indivíduos após 500 gerações. (a) Topologia NSFNet. (b) Topologia Finlândia.

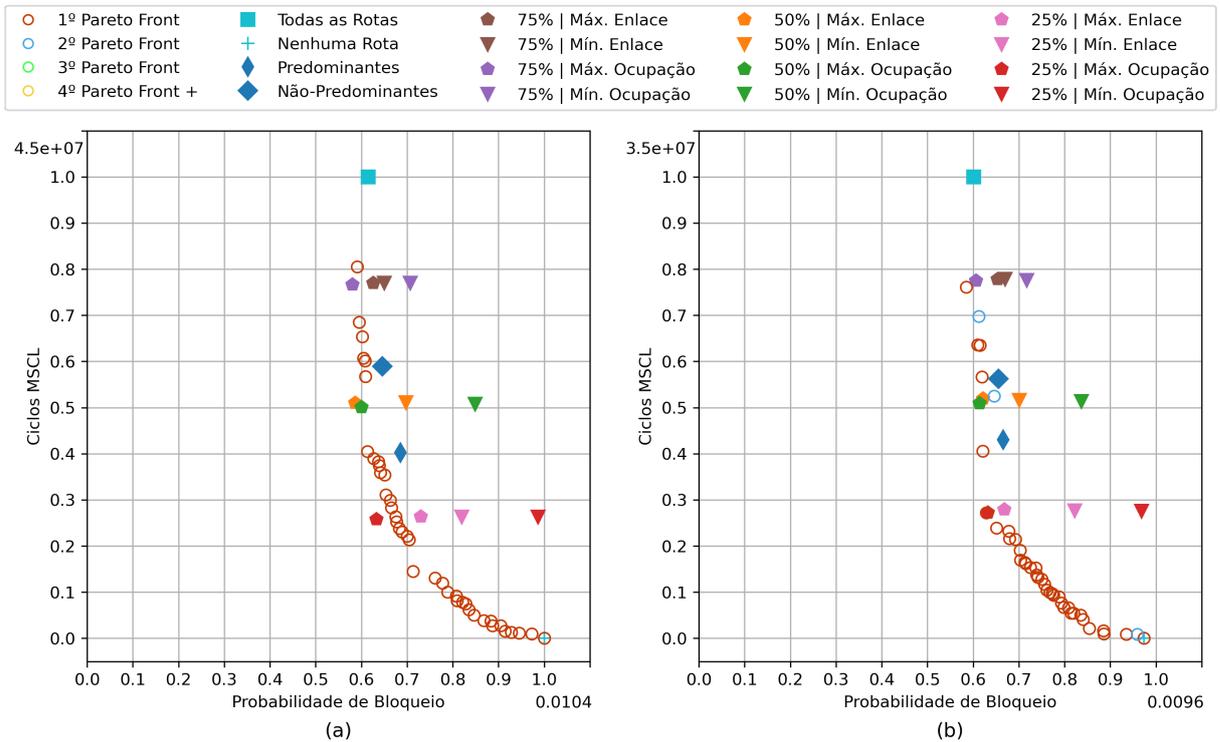


Fonte: Elaborado pelo Autor (2021).

A Figura 36 mostra a frente de Pareto após 500 gerações ao utilizar o cruzamento do tipo 2. Houve pouca variação entre ambos os operadores, entretanto, o cruzamento do tipo 2 conseguiu obter soluções mais diversificadas com bom desempenho de probabilidade de bloqueio na região entre 0,5 e 0,8 Ciclos MSCL. As soluções dispostas em uma frente de Pareto deixa a cargo do projetista de uma rede óptica qual decisão tomar para melhor satisfazer as necessidades do projeto. Em ambos os operadores de cruzamento, foi possível obter uma solução com melhor desempenho em probabilidade de bloqueio comparado com o desempenho do MSCL tradicional.

Concluindo as análises das heurísticas, os resultados das soluções obtidas pelo algoritmo genérico serão apresentados seguindo os parâmetros da Tabela 1, expandido para outras cargas da rede. Para a comparação entre heurísticas de otimização serão usados os seguintes conjuntos de rotas interferentes para $k = 1$: Todas as Rotas; 50% do conjunto formado pelos caminhos

Figura 36 – Frentes de Pareto para o algoritmo genético com cruzamento do tipo 2. População de indivíduos após 500 gerações. (a) Topologia NSFNet. (b) Topologia Finlândia.



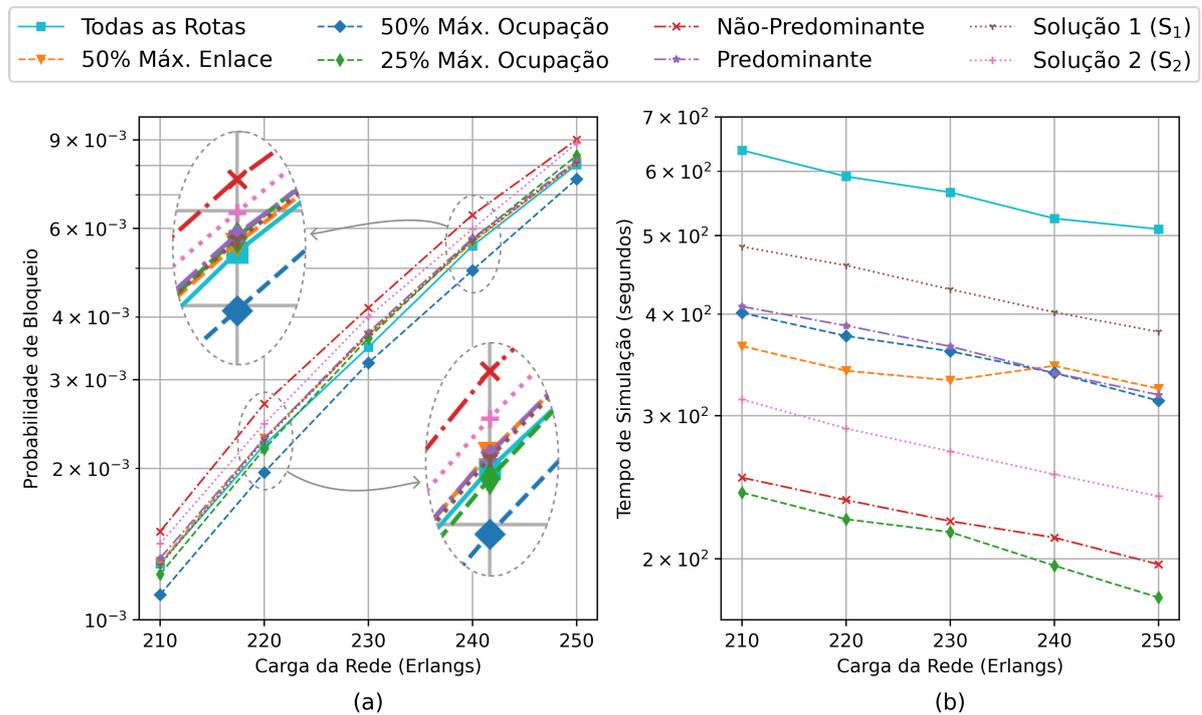
Fonte: Elaborado pelo Autor (2021).

com mais enlaces; 50 e 25% das rotas com a maior ocupação do *slots*; conjunto Predominante e Não-Predominante; e as soluções S_1 e S_2 .

A Figura 37 (a) apresenta a probabilidade de bloqueio em função da carga da rede, já a Figura 37 (b) são apresentados os tempos de simulação para obter esses resultados na topologia NSFNet. Devido à proximidade entre as probabilidades de bloqueio nas heurísticas apresentadas foi realizado uma aproximação nas cargas de 220 e 240 Erlangs. A melhor solução em probabilidade de bloqueio para a topologia NSFNet é obtida com a heurística de otimização “50% Máx. Ocupação”. Usando metade do conjunto interferente formado pelas rotas mais ocupadas, o algoritmo MSCL prioriza aquelas rotas em estado crítico de ocupação do espectro. Ao utilizar todas as rotas do conjunto interferente, as rotas menos ocupadas acabam por influenciar o cálculo da perda de capacidade, buscando alocações adequadas para elas, no entanto, podem estar fragmentando o espectro para aquelas que já apresentam uma menor capacidade.

O tempo de simulação dessa heurística é em média 36,69% menor que o MSCL padrão, mesmo essa otimização ocorrendo de forma dinâmica, sendo necessário ordenar as rotas a cada requisição. A heurística “50% Máx. Enlace” apresenta uma PB próxima ao MSCL padrão, no

Figura 37 – Topologia NSFNet em $k = 1$. (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede. (b) Comparativo entre o tempo de simulação *versus* carga da rede.



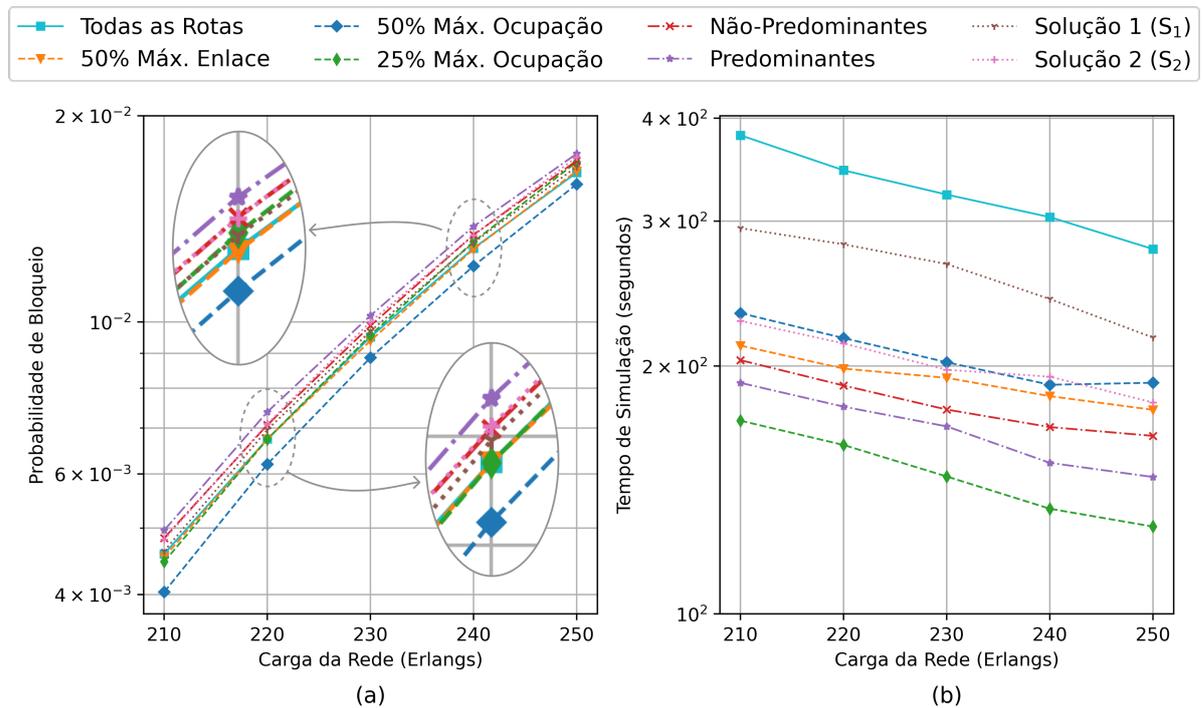
Fonte: Elaborado pelo Autor (2021).

entanto, mesmo apresentando uma ordenação fixa obtida antes de iniciar a simulação, o tempo final foi próximo ao da heurística de ocupação. A heurística mais rápida foi obtida usando 25% do conjunto ordenado pela maior ocupação. Em cargas inferior a 220 Erlangs, o valor da probabilidade de bloqueio chega a ser inferior ao do MSCL padrão.

A Figura 38 mostra os resultados para a topologia Finlândia. Os resultados se mostraram consistentes com a topologia NSFNet, no entanto, há uma inversão entre as heurísticas Predominantes e Não-Predominante em probabilidade de bloqueio e tempo de simulação. Essa inversão era esperada, conforme mostrado na Figura 25, devido a diferença dos conjuntos interferentes em ambas as topologias, são formados novos conjuntos com características distintas.

As soluções obtidas pelo algoritmo genético se mostraram eficazes em ambas as topologias, mas não devem ser priorizadas devido ao alto tempo de execução quando observado o ganho que elas fornecem. Foram encontradas diversas solução empíricas que apresentam soluções equivalentes, sem a necessidade de evoluir toda uma população. Uma solução heurística simples é obtida usando metade do conjunto interferente ordenado pelas rotas com maiores números de enlaces.

Figura 38 – Topologia Finlândia em $k = 1$. (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede. (b) Comparativo entre o tempo de simulação *versus* carga da rede.

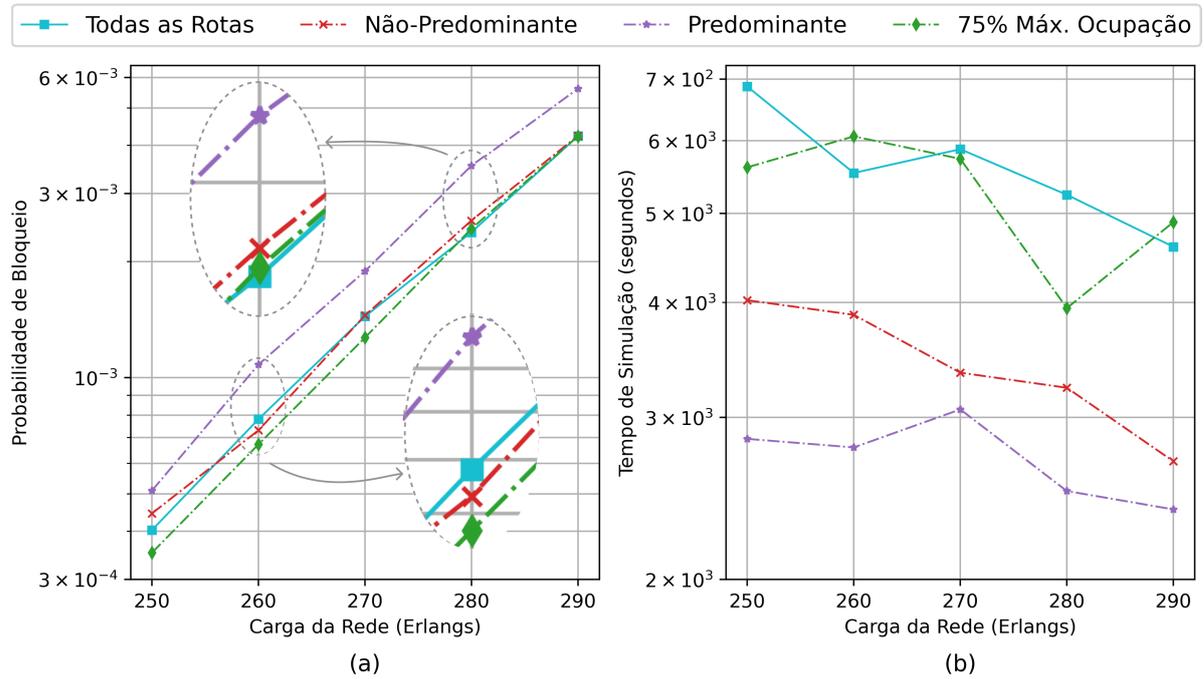


Fonte: Elaborado pelo Autor (2021).

As Figuras 39 e 40 mostram os resultados das heurísticas de otimização em $k = 2$ para as topologias NSFNet e Finlândia, respectivamente. Devido ao cronograma dessa pesquisa, não foi possível utilizar do algoritmo genético na obtenção de soluções para o problema. As heurísticas de otimização utilizadas foram: o MSCL padrão, 75% das rotas com a maior ocupação e o conjunto interferente formado pelas rotas Predominantes e Não-Predominantes. Em ambas as topologias, há uma proximidade de probabilidade de bloqueio entre elas, exceto a formada pelo conjunto Predominante. Na topologia NSFNet, o destaque de melhoria em PB é para o conjunto de máxima ocupação em 75%, visto a semelhança de tempo de simulação com o MSCL Padrão. A solução formada pelo conjunto Não-Predominante apresentou uma solução satisfatória em probabilidade de bloqueio e com redução do tempo de simulação.

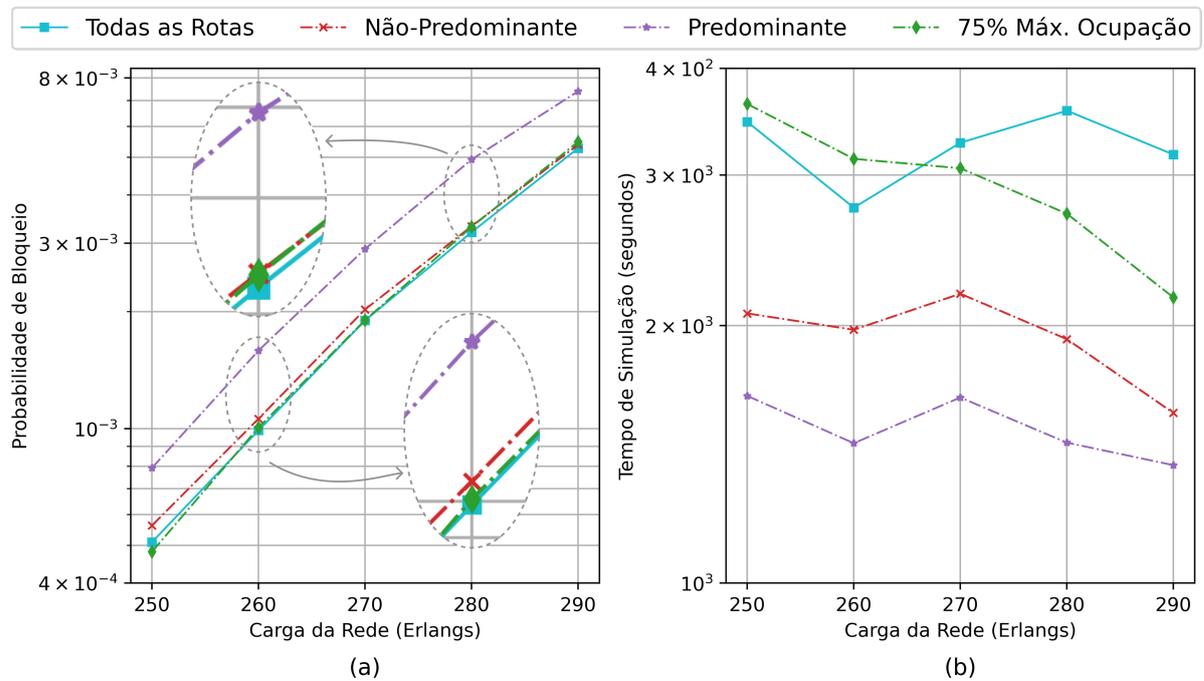
Conforme os resultados apresentados neste capítulo, é possível perceber que as heurísticas de otimização desempenham um grande papel de melhoria aos algoritmos MSCL. O ganho de desempenho em tempo de execução sem prejudicar a probabilidade de bloqueio é mais uma das contribuições dessa pesquisa. Em um cenário em que não é possível encontrar uma solução ótima, as heurísticas propostas apresentam boas soluções ao problema de roteamento e alocação de espectro.

Figura 39 – Topologia NSFNet em $k = 2$. (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede. (b) Comparativo entre o tempo de simulação *versus* carga da rede.



Fonte: Elaborado pelo Autor (2021).

Figura 40 – Topologia Finlândia em $k = 2$. (a) Comparativo entre a probabilidade de bloqueio *versus* carga da rede. (b) Comparativo entre o tempo de simulação *versus* carga da rede.



Fonte: Elaborado pelo Autor (2021).

5 CONCLUSÕES

Esta dissertação apresentou heurísticas inéditas para solucionar o problema de roteamento e alocação de espectro, aliado ao problema de fragmentação do espectro em redes ópticas elásticas. As heurísticas, intituladas MSCL Sequencial e MSCL Combinado, recorrem ao conjunto de múltiplas rotas para minimizar a perda de capacidade após a alocação dos slots de frequência. Os resultados do Capítulo 3 mostram que a heurística MSCL Combinado se sobressai ao MSCL Sequencial e First-Fit, inclusive em cenários em que é feito a distribuição da carga entre o conjunto de rotas. A melhoria do MSCL Combinado chegou a ser de 76,63% ao comparar com o First-Fit para a topologia NSFNet em um cenário de 3 rotas para cada par origem-destino. O MSCL Sequencial perde em probabilidade de bloqueio, mas ganha em desempenho, sendo um algoritmo mais rápido.

O compromisso entre essas duas métricas proporcionaram uma abordagem multi-objetiva, objetivando um melhor balanço entre ambas. No Capítulo 4 foi proposta uma nova métrica para mensurar o desempenho das heurísticas, chamado Ciclos MSCL. Essa métrica, correlata ao tempo de simulação, foi necessária devido à variação que o tempo de simulação é suscetível. Novas meta-heurísticas de otimização foram propostas, de modo a melhorar o desempenho das heurísticas MSCL. Dentre elas, a heurística de otimização que melhor cumpriu o objetivo, é a técnica de ordenar o conjunto de rotas interferentes a partir das rotas mais ocupadas, considerando somente uma fração desse conjunto. Essa técnica conseguiu melhorar a probabilidade de bloqueio em 8,62% e o tempo de simulação em 36,69%, podendo chegar a 62,64% de ganho no tempo de simulação, sacrificando 2,67% de probabilidade de bloqueio, quando usado 25% do conjunto interferente comparado com o MSCL que recorre a todas as rotas.

Com o intuito de encontrar o melhor compromisso entre as métricas estudadas, foi proposto um algoritmo genético multi-objetivo que eliminará rotas do conjunto interferente. Os métodos desenvolvidos proporcionaram a evolução dos indivíduos, que ao término da convergência, formaram uma frente de Pareto apresentando 40 escolhas diferentes para solucionar o problema. A escolha entre as soluções da frente de Pareto priorizaram a menor probabilidade de bloqueio, no entanto, o tempo de simulação obtido foi menor quando comparado ao MSCL padrão.

Todas as heurísticas e suas otimizações apresentaram resultados consistentes quando simulados para as topologias NSFNet e Finlândia, concluindo-se que esses resultados devem ser mantidos para diferentes topologias.

5.1 PUBLICAÇÃO

As propostas apresentadas no Capítulo 3 dessa dissertação foram publicadas no XXXIX Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT) no ano de 2021, sob o título “Heurísticas para Atribuição de Espectro em Redes Ópticas Elásticas Baseadas em Perda de Capacidade Sob Múltiplas Rotas”. Diferente desta dissertação, neste artigo são considerados os impactos de camada física.

Um artigo sobre os assuntos abordados no capítulo 4 está em fase de desenvolvimento.

5.2 TRABALHOS FUTUROS

Em trabalhos futuros deve-se investigar outras formas de calcular a perda de capacidade em múltiplas rotas. O método descrito nessa dissertação utiliza um somatório em todas as rotas do conjunto interferentes, sendo o valor obtido a perda de capacidade na rota principal. O MSCL Combinado compara as rotas utilizando esse valor para efetuar a escolha da melhor alocação, no entanto, as rotas podem apresentar quantias diferentes de rotas interferentes e a comparação pode não ser totalmente justa. Um algoritmo PSO pode ser utilizado para ponderar o custo do conjunto interferente, para igualar rotas com mais ou com menos rotas interferentes.

Novas abordagens podem ser adotadas para se obter as métricas de ordenação apresentadas no Capítulo 4. Essa dissertação utiliza o conceito de quantidade de *slots* ocupado como ocupação da rota, mas outras métricas podem ser adotadas, como o número de formas.

REFERÊNCIAS

- ALMEIDA-JR., R. C.; SANTOS, A. F. d.; ASSIS, K.; WALDMAN, H.; MARTINS-FILHO, J. Slot assignment strategy to reduce loss of capacity of contiguous-slot path requests in flexible grid optical networks. *Electronics Letters*, Wiley Online Library, v. 49, n. 5, p. 359–361, 2013.
- ALVES, M. M.; ALMEIDA-JR., R. C.; SANTOS, A. F. dos; PEREIRA, H. A.; ASSIS, K. D. Impairment-aware fixed-alternate bsr routing heuristics applied to elastic optical networks. *The Journal of Supercomputing*, Springer, v. 77, p. 1475–1501, 2021.
- ARAÚJO, D. R.; BASTOS-FILHO, C. J.; BARBOZA, E. A.; CHAVES, D. A.; MARTINS-FILHO, J. F. An efficient multi-objective evolutionary optimizer to design all-optical networks considering physical impairments and capex. In: IEEE. *2011 11th International Conference on Intelligent Systems Design and Applications*. [S.l.], 2011. p. 76–81.
- ARAÚJO, D. R. B. d. *Planejamento de redes ópticas usando inteligência computacional e ciência das redes*. Tese (Doutorado) — Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Recife, 2015.
- ATA, N. A. E.; PERKS, M. J. *Solving the Dynamic Complexity Dilemma*. [S.l.]: Springer, 2016.
- CASTRO, L. N. D.; ZUBEN, F. J. V. *Recent developments in biologically inspired computing*. [S.l.]: Igi Global, 2005.
- CAVALCANTE, M.; PEREIRA, H.; ALMEIDA-JR., R. Simeon: an open-source elastic optical network simulator for academic and industrial purposes. *Photonic Network Communications*, v. 34, 10 2017.
- CAVALCANTE, M. A.; PEREIRA, H. A.; CHAVES, D. A.; ALMEIDA-JR., R. C. Optimizing the cost function of power series routing algorithm for transparent elastic optical networks. *Optical Switching and Networking*, Elsevier, v. 29, p. 57–64, 2018.
- CHATTERJEE, B. C.; SARMA, N.; OKI, E. Routing and spectrum allocation in elastic optical networks: A tutorial. *IEEE Communications Surveys & Tutorials*, IEEE, v. 17, n. 3, p. 1776–1800, 2015.
- CHAVES, D. A.; PEREIRA, H. A.; BASTOS-FILHO, C. J.; MARTINS-FILHO, J. F. Simton: A simulator for transparent optical networks. *Journal of Communication and Information Systems*, v. 25, n. 1, 2010.
- CHIVERS, I.; SLEIGHTHOLME, J. An introduction to algorithms and the big o notation. In: *Introduction to programming with Fortran*. [S.l.]: Springer, 2015. p. 359–364.
- CISCO. *Cisco Annual Internet Report (2018–2023) White Paper*. 2020. Disponível em: <<https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>>.
- COELLO, C. A. C.; LAMONT, G. B.; VELDHUIZEN, D. A. V. et al. *Evolutionary algorithms for solving multi-objective problems*. [S.l.]: Springer, 2007. v. 5.

- DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE transactions on evolutionary computation*, IEEE, v. 6, n. 2, p. 182–197, 2002.
- DIJKSTRA, E. W. et al. A note on two problems in connexion with graphs. *Numerische mathematik*, v. 1, n. 1, p. 269–271, 1959.
- DINARTE, H. A.; CORREIA, B. V.; CHAVES, D. A.; ALMEIDA-JR., R. C. Routing and spectrum assignment: A metaheuristic for hybrid ordering selection in elastic optical networks. *Computer Networks*, Elsevier, v. 197, p. 108287, 2021.
- FELDMANN, A.; GASSER, O.; LICHTBLAU, F.; PUJOL, E.; POESE, I.; DIETZEL, C.; WAGNER, D.; WICHTLHUBER, M.; TAPIADOR, J.; VALLINA-RODRIGUEZ, N. et al. Implications of the covid-19 pandemic on the internet traffic. In: VDE. *Broadband Coverage in Germany; 15th ITG-Symposium*. [S.l.], 2021. p. 1–5.
- FIGUEIRÔA, E. O.; LIMA, E. A. O.; BASTOS-FILHO, C. J. A.; SILVA, J. C. da; XAVIER, A. V. S.; ARAÚJO, D. R. B. A routing algorithm based on fuzzy logics for elastic optical networks. In: *2017 IEEE 18th International Conference on High Performance Switching and Routing (HPSR)*. [S.l.: s.n.], 2017. p. 1–6.
- FILHO, P. de S.; ALMEIDA-JR, R. C. Redução da perda de capacidade em redes Ópticas elásticas com multiplexação espacial. In: *XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBRT 2018)*. Campina Grande, PB: [s.n.], 2018.
- FILHO, P. F. d. S. *Proposta de heurística e meta-heurística para alocação eficiente de recursos em redes com multiplexação por divisão espacial*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2018.
- FONSECA, I. E. d. *Uma abordagem para provisionamento e diferenciação de QoS óptico na presença de FWM em redes ópticas transparentes*. Tese (Doutorado) — Universidade Federal de Campinas, Faculdade de Engenharia Elétrica e de Computação, São Paulo, 2005.
- FREITAS, F. d.; MAIA, C. L. B.; COUTINHO, D. P.; CAMPOS, G.; SOUZA, J. Aplicação de metaheurísticas em problemas da engenharia de software: Revisão de literatura. In: *II Congresso Tecnológico Infobrasil*. [S.l.: s.n.], 2009.
- GERSTEL, O.; JINNO, M.; LORD, A.; YOO, S. B. Elastic optical networking: a new dawn for the optical layer? *IEEE Communications Magazine*, v. 50, n. 2, p. s12–s20, 2012.
- GOLBARG, M. C.; LUNA, H. P. L. *Otimização Combinatória e Programação Linear*. 2. ed. Rio de Janeiro: Elsevier, 2005.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1st. ed. USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.
- HOLLAND, J. H. et al. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. [S.l.]: MIT press, 1992.
- HOROTA, A. K. *Algoritmos de roteamento e atribuição de espectro com minimização de fragmentação em redes ópticas elásticas*. Dissertação (Mestrado) — Universidade Federal da Bahia, Instituto de Matemática, Salvador, 2016.

- ITU-T G.694.1. *Spectral grids for WDM applications: DWDM frequency grid*. [S.l.], 2020. Disponível em: <<http://handle.itu.int/11.1002/1000/11830-en>>.
- JINNO, M.; TAKARA, H.; KOZICKI, B.; TSUKISHIMA, Y.; SONE, Y.; MATSUOKA, S. Spectrum-efficient and scalable elastic optical path network: architecture, benefits, and enabling technologies. *IEEE communications magazine*, IEEE, v. 47, n. 11, p. 66–73, 2009.
- KEISER, G. *Comunicações por Fibras Ópticas*. 4. ed. Porto Alegre: AMGH, 2014.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95-international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948.
- KHODASHENAS, P. S.; COMELLAS, J.; SPADARO, S.; PERELLÓ, J.; JUNYENT, G. Using spectrum fragmentation to better allocate time-varying connections in elastic optical networks. *J. Opt. Commun. Netw., OSA*, v. 6, n. 5, p. 433–440, May 2014. Disponível em: <<http://jocn.osa.org/abstract.cfm?URI=jocn-6-5-433>>.
- KLINKOWSKI, M.; ŻOTKIEWICZ, M.; WALKOWIAK, K.; PIÓRO, M.; RUIZ, M.; VELASCO, L. Solving large instances of the rsa problem in flexgrid elastic optical networks. *Journal of Optical Communications and Networking*, Optical Society of America, v. 8, n. 5, p. 320–330, 2016.
- KO, K.-T.; TANG, K.-S.; CHAN, C.-Y.; MAN, K.-F.; KWONG, S. Using genetic algorithms to design mesh networks. *Computer*, IEEE, v. 30, n. 8, p. 56–61, 1997.
- LINDEN, R. *Algoritmos genéticos*. 2. ed. Rio de Janeiro: Brasport, 2008.
- LIRA, C. J.; ALMEIDA-JR., R.; CHAVES, D. A. Estratégias de rsa utilizando split spectrum e o algoritmo mscl em eons. In: *XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2020)*. Florianópolis, SC: [s.n.], 2020.
- LIRA, C. N.; ALMEIDA-JR., R. C.; CHAVES, D.; WALDMAN, H.; ASSIS, K. Meta-heuristic procedure for enhanced spectrum fragmentation assessment in elastic optical networks. *Journal of Communication and Information Systems*, v. 35, n. 1, p. 333–337, 2020.
- LUO, B.; ZHENG, J.; XIE, J.; WU, J. Dynamic crowding distance? a new diversity maintenance strategy for moeas. In: IEEE. *2008 Fourth International Conference on Natural Computation*. [S.l.], 2008. v. 1, p. 580–585.
- NAKAMURA, M.; MATSUSHITA, A.; OKAMOTO, S.; HAMAOKA, F.; KISAKA, Y. Spectrally efficient 800 gbps/carrier wdm transmission with 100-ghz spacing using probabilistically shaped pdm-256qam. In: IEEE. *2018 European Conference on Optical Communication (ECOC)*. [S.l.], 2018. p. 1–3.
- NOOMIS. *Previsto para 2022, 5G deve revolucionar a internet no Brasil*. 2021. Disponível em: <<https://noomis.febraban.org.br/temas/internet-das-coisas/previsto-para-2022-5g-deve-revolucionar-a-internet-no-brasil>>.
- PAIVA, M. H. M. *Aplicação de sistemas baseados em regras fuzzy para o roteamento em redes Ópticas*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, Centro Tecnológico, Espírito Santo, 2008.
- RAMASWAMI, R.; SIVARAJAN, K.; SASAKI, G. *Optical networks: a practical perspective*. 3. ed. [S.l.]: Elsevier, 2009.

-
- REEVES, C. R. Genetic algorithms. In: *Handbook of metaheuristics*. [S.l.]: Springer, 2010. p. 109–139.
- RUIZ, L.; GONZALEZ, I.; DURÁN, R.; MIGUEL, I. de; MERAYO, N.; AGUADO, J.; FERNANDEZ, P.; LORENZO, R.; ABRIL, E. Comparing different types of flexibility when solving the rsa problem in eons. In: IEEE. *2017 International Conference on Computational Science and Computational Intelligence (CSCI)*. [S.l.], 2017. p. 1356–1359.
- SANTOS, A.; ALMEIDA-JR., R.; ASSIS, K. Yen-bsr: a new approach for the choice of routes in wdm networks. *Journal of Optical Communications*, De Gruyter, v. 35, n. 4, p. 293–296, 2014.
- SANTOS, M. L. dos; ALMEIDA-JR., R. C.; ARAÚJO, D. R. B. Heurísticas para atribuição de espectro em redes Ópticas elásticas baseadas em perda de capacidade sob múltiplas rotas. In: *XXXIX Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBRT 2021)*. Fortaleza/Virtual, Brazil: [s.n.], 2021.
- SILVA, J. C. da; BASTOS-FILHO, C. J.; COUTO, I. d. S.; XAVIER, A. V. et al. Uma abordagem de otimização para o algoritmo de roteamento utilizando lógica nebulosa. Recife, 2018.
- SOBREIRO, V. A. *Proposta de uma heurística construtiva baseada na teoria das restrições para definição de mix de produção*. Tese (Doutorado) — Universidade de São Paulo, 2012.
- XAVIER, A. V. S. *Roteamento e proteção dedicada em redes ópticas usando inteligência computacional*. Tese (Doutorado) — Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Recife, 2016.
- YEN, J. Y. Finding the k shortest loopless paths in a network. *management Science*, *Inform*s, v. 17, n. 11, p. 712–716, 1971.
- ZANAKIS, S. H.; EVANS, J. R. Heuristic “optimization”: Why, when, and how to use it. *Interfaces*, *INFORMS*, v. 11, n. 5, p. 84–91, 1981.

APÊNDICE A – VETOR DE OCUPAÇÃO GERAL

Conforme explicado na Seção 2.1, o vetor de disponibilidade resultante em uma rota é formado a partir da combinação dos enlaces que a compõe. Normalmente a maioria dos simuladores de redes ópticas elásticas utilizam uma estrutura orientada a objetos em seus componentes, como é o caso do simulador adaptado nesta dissertação. O espectro de frequência de cada enlace da rede é implementado a partir de um vetor de bits 0 e 1. Nestes vetores o 0 simboliza que o índice correspondente ao *slot* está disponível para ser alocada uma requisição, já o valor 1 indica a ocupação do *slot*. Durante os algoritmos de alocação de espectro é necessário verificar se um conjunto de *slots* estão disponíveis para serem alocados em uma rota. Usando uma requisição que necessita do conjunto $\{0,1,2\}$ como exemplo, é necessário garantir que todos os enlaces que compõem a rota estejam livre nesses índices.

Para obter-se o número de *slots* ocupados em uma rota, seguindo essa lógica, é necessário analisar todos os índices de cada um dos enlaces. Uma nova abordagem adotada nessa dissertação poupa essa análise, utilizando pequenas modificações em estruturas pré-existentes. Na classe de programação que modela uma rota são adicionados duas novas variáveis. A primeira é uma variável O_r que armazena o número indicando a ocupação nessa rota no decorrer de simulação. A outra é um vetor de ocupação geral V_r , que pode receber números naturais de 0 até o máximo de *slots* configurado no simulador. O número em cada índice representa a ocupação, para o mesmo índice, em todos os enlaces da rota.

O processo de incrementar a ocupação é realizado durante o método de alocação da requisição. Ao alocar uma *slot* na posição 0 em uma rota é necessário incrementar em uma unidade o índice 0 da variável V_r desta rota, bem como a variável de todas as rotas interferentes a ela. Caso o valor do vetor de disponibilidade mude de 0 para 1 é incrementado uma unidade na variável O_r , que armazena a ocupação da rota. Se o valor do vetor de disponibilidade diferir de 0 antes da alocação, nada será feito com a ocupação.

O processo de retirar a ocupação é semelhante, realizado no método que desaloca as requisições da rede. Para retirar a ocupação de um *slot* é realizado a subtração em uma unidade da posição correspondente no vetor V_r na rota principal e em todas as rotas interferentes. Para que a ocupação seja reduzida o valor do vetor de disponibilidade deve modificar de 1 para 0, se a transição ocorrer em qualquer outro valor a ocupação é mantida.