



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA APLICADA

JORGE CANDEIAS DO NASCIMENTO

PROJETO DE REDES ÓPTICAS DE LONGA
DISTÂNCIA APOIADO POR ALGORITMOS
MEMÉTICOS QUE CONSIDERAM VÁRIOS
OBJETIVOS CONFLITANTES.

RECIFE – PE

2021

JORGE CANDEIAS DO NASCIMENTO

**PROJETO DE REDES ÓPTICAS DE LONGA
DISTÂNCIA APOIADO POR ALGORITMOS
MEMÉTICOS QUE CONSIDERAM VÁRIOS
OBJETIVOS CONFLITANTES.**

Dissertação submetida à Coordenação do
Programa de Pós-Graduação em Informática
Aplicada - Universidade Federal Rural de
Pernambuco, como parte dos requisitos
necessários para obtenção do grau de Mestre.

ORIENTADOR: Danilo Ricardo Barbosa Araújo

CO-ORIENTADOR: Péricles Barbosa Cunha de Miranda

RECIFE – PE

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- N124p Nascimento, Jorge Candeias do
PROJETO DE REDES ÓPTICAS DE LONGADISTÂNCIA APOIADO POR ALGORITMOS MEMÉTICOS
QUE CONSIDERAM VÁRIOS OBJETIVOS CONFLITANTES. / Jorge Candeias do Nascimento. - 2021.
131 f. : il.
- Orientador: Danilo Ricardo Barbosa Araujo.
Coorientador: Pericles Barbosa Cunha de Miranda.
Inclui referências.
- Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em
Informática Aplicada, Recife, 2021.
1. Local search. 2. Pivot rules. 3. Optical network topology. 4. NSGAIII. 5. Optical network technologies.
I. Araujo, Danilo Ricardo Barbosa, orient. II. Miranda, Pericles Barbosa Cunha de, coorient. III. Título

JORGE CANDEIAS DO NASCIMENTO

**PROJETO DE REDES ÓPTICAS DE LONGA
DISTÂNCIA APOIADO POR ALGORITMOS
MEMÉTICOS QUE CONSIDERAM VÁRIOS
OBJETIVOS CONFLITANTES.**

Dissertação submetida à Coordenação do
Programa de Pós-Graduação em Informática
Aplicada - Universidade Federal Rural de
Pernambuco, como parte dos requisitos
necessários para obtenção do grau de Mestre.

Aprovada em: 10 de agosto de 2021.

BANCA EXAMINADORA

Danilo Ricardo Barbosa Araújo (Orientador)
Universidade Federal Rural de Pernambuco
Departamento de Computação - DC

Cícero Garrozi
Universidade Federal Rural de Pernambuco
Departamento de Estatística e Informática - DEINFO

Carmelo J. A. Bastos-Filho
Universidade de Pernambuco
Departamento de Sistemas Computacionais

Em memória de Ivonete Candeias de Oliveira,
minha doce mãe. Ah mãe, que falta a senhora
faz a mim e aos meus irmãos.

Agradecimentos

Agradeço a Deus por todas as conquistas, sempre que as forças se acabam ele me ampara. Agradeço a educação que minha mãe, Ivonete Candeias, me deu para aprender que nada é impossível com obstinação e trabalho duro.

Agradeço a meus orientadores, Danilo Araújo e Péricles Miranda que forjaram comigo a qualidade do nosso trabalho. Agradeço a Eduardo Chaves, o secretário do Programa de Pós Graduação em Informática Aplicada Universidade Federal Rural de Pernambuco (PPGIA-UFRPE), por toda assistência acadêmica administrativa prestado. Eduardo não poupa esforços para ajudar os discentes do curso.

Agradeço a minha esposa e filhos que me movem sempre para frente, minha esposa, Maria Edilene, que tanto me apoia e os meus filhos, Maria Izabel e Jorge Raphael. Meus filhos desempenham um papel importante na minha insistência em estudar cada vez mais que é a vontade de deixar um exemplo robusto para eles.

Agradeço a meus Irmãos, dos quais irei citar os nomes e os apelidos, porque era assim que minha mãe os chamava, Angelina (Dala), Albina (Bina), Sandro (Doca) e Severino (Bill), vocês sempre estão e sempre estarão em minhas orações.

"Não se trata de bater forte. Se trata de quanto você aguenta apanhar e seguir em frente, o quanto você é capaz de aguentar e continuar tentando. É assim que se consegue vencer."

(Trecho do discurso de Rocky Balboa para o seu filho no filme Rocky Balboa)

Resumo

Nos dias de hoje, Internet de qualidade é um dos requisitos funcionais da vida. Neste cenário, uma tecnologia de transmissão de dados vem se destacando: é transmissão por fibra óptica. Um dos desafios em se implantar uma rede de fibra óptica é o projeto da topologia da rede. Basicamente, em um projeto de topologias de redes ópticas é preciso apresentar os nós terminais, a forma com que os enlaces interconectam os nós terminais e a configuração dos equipamentos que irão compor os nós terminais. A combinação de todas essas questões técnicas é um problema combinatório *NP-hard*. Por este motivo, na literatura há muitos exemplos de tratamento do problema do projeto da topologia de redes de fibra óptica através de um algoritmo evolucionário. Um algoritmo evolucionário é um algoritmo inspirado na evolução das espécies. Um algoritmo evolucionário simula a evolução das espécies, pegando soluções para um dado problema, e evoluindo essa solução através de operadores computacionais que simulam o cruzamento e reprodução de suas soluções, como se fossem a gerações de pais e filhos. Geralmente, as melhores soluções são escolhidas para serem pais, e, os filhos têm boa chance de se parecerem com os pais e ainda ter alguma vantagem. Todavia, um algoritmo evolucionário clássico pode não conseguir resolver um problema complexo, como o problema do projeto da topologia de redes ópticas, de forma mais robusta. Talvez seja preciso alguma especialização para o algoritmo. Uma maneira de especializar um algoritmo evolucionário para um determinado problema é inserir em seu fluxo um procedimento que implemente conhecimento do problema. Esse procedimento é chamado de busca local e um algoritmo evolucionário com uma busca local é chamado de algoritmo memético. Já há relatos da literatura de que um algoritmo memético consegue melhorar as soluções de um algoritmo evolucionário quando está lidando com o problema do projeto de topologia de redes. Entretanto, o custo computacional, causado pelo procedimento da busca local, muitas vezes invalida a abordagem. Esse trabalho tem como objetivo, experimentar diversas regras do *pivot* para reduzir o custo computacional extra que um algoritmo evolucionário tem em uma versão memética. Os experimentos revelam que, além da mitigação da questão do custo computacional, foi possível encontrar resultados até 8% melhores que resultados encontrados na literatura.

Palavras-chave: Busca local, NSGAIII, Regras do *pivot*, Algoritmo evolucionário, Topologia de redes ópticas, Tecnologias de redes ópticas.

Abstract

Quality internet is one of the functional requirements of life. In this scenario, a data transmission technology has been standing out: it is fiber optic transmission. One of the challenges in deploying a fiber optic network is the design of the network topology. Basically, in a project of optical network topologies, it is necessary to present the terminal nodes, the way the links interconnect the terminal nodes and the configuration of the equipment that will make up the terminal nodes. The combination of all these technical issues is a *NP-hard* combinatorial problem. For this reason, in the literature there are many examples of handling the problem of designing the topology of fiber optic networks using an evolutionary algorithm. An evolutionary algorithm is an algorithm inspired by the evolution of species. An evolutionary algorithm simulates the evolution of species, taking solutions to a given problem, and evolving that solution through computational operators that simulate the crossing and reproduction of their solutions, as if they were generations of parents and children. Generally, the best solutions are chosen to be parents, and children have a good chance of looking like their parents and still have some advantage. However, a classical evolutionary algorithm may not be able to solve a complex problem, such as the optical network topology design problem, more robustly. Maybe you need some specialization for the algorithm. One way to specialize an evolutionary algorithm for a given problem is to insert into its flow a procedure that implements knowledge of the problem. This procedure is called a local search, and an evolutionary algorithm with a local search is called a memetic algorithm. There are already reports in the literature that a memetic algorithm can improve the solutions of an evolutionary algorithm when dealing with the problem of network topology design. However, the computational cost caused by the local search procedure often invalidates the approach. This work aims to experiment with different *pivot* rules to reduce the extra computational cost that an evolutionary algorithm has in a memetic version. The experiments reveal that, in addition to mitigating the computational cost issue, it was possible to find results up to 8% better than results found in the literature.

Keywords: Local search, NSGAIII, Pivot rules, Genetic algorithm, Optical network topology, Optical network technologies.

Lista de Figuras

Figura 1 – Um exemplo simples e ilustrativo de duas topologias para uma única demanda de projeto de redes.	19
Figura 2 – O PTD proposto em um trabalho anterior: o benchmark principal dessa pesquisa - (NASCIMENTO et al., 2018).	20
Figura 3 – Exemplo de funcionamento da busca local proposta em (NASCIMENTO et al., 2018).	22
Figura 4 – Ilustrando o entendimento do problema: uma matriz de conexão para uma topologia de quatro nós terminais.	26
Figura 5 – Mitigação de custos no projeto de redes ópticas através da variação de tecnologias: mescla de redes de transporte e redes metropolitanas. . . .	41
Figura 6 – Operador seleção dos sobreviventes especializado em distribuição: o hiperplano normatizado.	52
Figura 7 – Visão do espalhamento das soluções do problema clássico DTLZ1 resolvido pelo NSGA-III.	53
Figura 8 – Visualização de vizinhança de uma solução, máximos locais e máximo globais em um problema de maximização.	56
Figura 9 – Área do <i>hypervolume</i> em um problema de minimização com os objetivos normatizados entre 0 e 1.	59
Figura 10 – Esquema geral da proposta.	64
Figura 11 – População de um EA baseada em dominância, distribuição em frentes de Pareto.	67
Figura 12 – Hiperplano normatizado sendo setorizado em um mínimo de M objetivos arranjados M a M , para 3 objetivos 6 setores, simbolizando possíveis localizações espaciais na curva de Pareto única.	68
Figura 13 – Setores do hiperplano normatizado sendo agrupados em M onde M é o número de objetivos.	69
Figura 14 – Hiperplano normatizado com uma distribuição precária das soluções. .	71
Figura 15 – Exemplo de atuação da busca local em vizinho de menor distância BLVMD.	79
Figura 16 – Layout da topologia de rede de região da MEDIANET Alemanha. . . .	91

Figura 17 – Layout de topologia do PTD apresentado em (NASCIMENTO et al., 2018)	91
Figura 18 – Comparação entre a <i>AB 1</i> e a <i>AB 2</i> duas abordagens com exploração da vizinhança Expl1.	98
Figura 19 – Comparação entre a <i>AB 3</i> e a <i>AB 4</i> duas abordagens com exploração da vizinhança Expl1.	99
Figura 20 – Comparação entre a <i>AB 5</i> e a <i>AB 6</i> duas abordagens com exploração da vizinhança Expl3.	100
Figura 21 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens <i>AB 5</i> e <i>AB 6</i>	101
Figura 22 – PTD com melhor CA para a abordagem <i>AB 6</i>	101
Figura 23 – Comparação entre <i>AB 7</i> e <i>AB 8</i> duas abordagens com exploração da vizinhança Expl1.	102
Figura 24 – Comparação entre <i>AB 9</i> e <i>AB 10</i> duas abordagens com exploração da vizinhança Expl3.	103
Figura 25 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens <i>AB 9</i> e <i>AB 10</i>	105
Figura 26 – PTD com melhor CAPEX para a abordagem <i>AB 10</i>	105
Figura 27 – Comparação de duas abordagens <i>AB 9</i> e <i>AB 11</i> duas abordagens para exploração Expl3.	106
Figura 28 – Comparação entre <i>AB 11</i> e <i>AB 12</i> duas abordagens com exploração da vizinhança Expl3 - 30 execuções.	107
Figura 29 – Comparação entre <i>AB 13</i> e <i>AB 12</i> uma abordagem com exploração da vizinhança Expl2 e outra com Expl3.	109
Figura 30 – Comparação entre <i>AB 12</i> , com Expl3 e <i>AB 14</i> com Expl1, a abordagem de (NASCIMENTO et al., 2018).	110
Figura 31 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens <i>AB 14</i> e <i>AB 12</i>	111
Figura 32 – Exemplos de PTDs com melhor PB para as abordagem <i>AB 14</i> e <i>AB 12</i>	112
Figura 33 – Comparação entre <i>AB 12</i> e <i>AB 14</i> em outro cenário de experimentos: a rede de região MEDIANET.	113

Figura 34 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens $AB\ 12$ e $AB\ 14$ no cenário da MEDIANET	115
Figura 35 – Exemplos de PTDs com melhor PB para as abordagens $AB\ 12$ e $AB\ 14$, no cenário da MEDIANET.	115
Figura 36 – Simulação de <i>exploration</i> pela realizado pela exploração da vizinhança Expl3.	121

Lista de Tabelas

Tabela 1 – Tabela de nicho escolhido entre os trabalhos relacionados.	38
Tabela 2 – Tabela de possibilidades para regras do <i>pivot</i>	57
Tabela 3 – Parâmetros simbólicos para configuração do NSGA-III.	89
Tabela 4 – Parâmetros numéricos para configuração do NSGA-III.	90
Tabela 5 – Tabela de configuração do simulador de redes SIMTON.	92
Tabela 6 – Tabela de configuração das regras do <i>pivot</i> : primeira rodada de experimentos.	94
Tabela 7 – Tabela da descrição da regra do <i>pivot</i> das abordagens apresentadas nos resultados.	97

Lista de Algoritmos

1	fast-non-dominated-sort para o NSGA-II e o NSGA-III	49
2	EA com busca local (LINDEN, 2008)	54
3	busca local (LINDEN, 2008)	55
4	Busca Local Baseada em Vizinho de Menor Distancia-BLVMD	74
5	VizinhosMaisProximos (Auxiliar 1- BLVMD)	75
6	Expl1 (Auxiliar 2- BLVMD)	76
7	Expl2 (Auxiliar 3- BLVMD)	77
8	Busca Local Baseada em Indivíduos Raro - BLBIR (Mating control)	82
9	Seleção de indivíduos na população, com privilégio para os raros, para entregar a Mescla da BLBIR e a BLVMD, nomeada de BLMES.	84
10	NSGA-III - HÍBRIDO	87

Lista de Siglas

BLBIR	Busca Local Baseada em Indivíduo Raro
BLVMD	Busca Local em Vizinhos de Menor Distância
BLMES	Busca Local Mesclada
CA	Conectividade Algébrica
CAPEX	<i>Capital Expenditures (Despesas de capital)</i>
CE	Consumo Energético
DWDM	<i>Dense Wavelength Division Multiplexing (Multiplexação densa por divisão de comprimento de onda)</i>
DCF	<i>Dispersion Compensate Fiber (Fibra de compensação de dispersão)</i>
EA	<i>Evolutionary Algorithm (Algoritmo evolucionário)</i>
Expl	Exploração
IP	<i>Internet Protocol (Protocolo de internet)</i>
MPLS	<i>Multiprotocol Label Switching (Comutação de Rótulos Multiprotocolo)</i>
NSGA-II	<i>Nondominated Sorting Genetic Algorithm II</i>
NSGA-III	<i>Nondominated Sorting Genetic Algorithm III</i>
OTL	<i>Optical Line Terminal (Terminal de linha ótica)</i>
OTN	<i>Optical Transport Networking (Rede de transporte óptico)</i>
PB	Probabilidade de Bloqueio
POP	<i>Point Of Presence (Ponto de presença - nó terminal da rede de transporte)</i>
PTD	<i>Physical Topology Design (Projeto físico de topologia)</i>
ROADM	<i>Reconfigurable optical add-drop multiplexers (Multiplexadores óticos reconfiguráveis add-drop)</i>
RWA	<i>Routing and Wavelength Association (Associação de roteamento e comprimento de onda)</i>
SSMF	<i>Standard Single Mode Fiber (Fibra única padrão)</i>

WDM *Wavelength Division Multiplexing (Multiplexação por divisão de comprimento de onda)*

Sumário

1	Introdução	18
1.1	Delimitação do Tema	23
1.2	Problema de Pesquisa	24
1.3	Objetivos	26
1.3.1	Objetivo Geral	27
1.3.2	Objetivo Específico	27
1.4	Organização do texto	28
2	Revisão da Literatura	29
2.1	Trabalhos relacionados com o PTD	29
2.2	Trabalhos relacionados com busca local	33
3	Fundamentação Teórica	39
3.1	Redes Ópticas	39
3.1.1	Topologia de rede	39
3.1.2	Tecnologias de redes ópticas	40
3.1.3	Nós terminais	41
3.2	Descrição das métricas de atributos do PTD	42
3.2.1	Probabilidade de bloqueio PB	42
3.2.2	Investimento capital com a implantação da rede CAPEX	43
3.2.3	Consumo energético	45
3.2.4	Conectividade algébrica - CA	46
3.2.5	Carga de tráfego em erlang	46
3.3	Algoritmos Evolucionários	47
3.3.1	NSGA-III	48
3.3.2	Torneio binário	50
3.3.3	Operador de seleção dos sobreviventes	51
3.3.4	Operador de busca local	53
3.3.5	Regra do <i>pivot</i>	55
3.3.6	<i>Hypervolume</i>	59
4	Proposta	60
4.0.1	Representação técnica do problema do PTD	60

4.1	Proposta deste estudo	63
4.2	O problema do Pareto único	66
4.3	Indivíduo raro	67
4.4	Melhorando a distribuição através do conceito de indivíduo raro	71
4.5	BLVMD - Busca Local em Vizinhos por Menor Distância	72
4.5.1	Exemplo de busca local BLVMD	78
4.6	Busca Local Baseada em Indivíduos Raros - BLBIR	79
4.6.1	Mecanismo da BLBIR	80
4.7	Mescla da BLBIR com A BLVMD	84
5	Metodologia	89
5.1	Configuração do NSGA-III	89
5.2	Configuração do SIMTON.	90
5.3	Critério de parada	93
5.4	Configurações da Regra do <i>pivot</i> para a busca local	93
6	Resultados	96
6.1	Resultados da abordagem de escolha aleatória	97
6.2	Seleção no grupo de indivíduos raros	102
6.3	Abordagem mais promissora <i>versus</i> a menos promissora e as regras do <i>pivot</i> de (NASCIMENTO et al., 2018)	108
6.3.1	A abordagem mais promissora <i>versus</i> a menos promissora	109
6.3.2	A abordagem mais promissora <i>versus</i> as regras do <i>pivot</i> de (NASCIMENTO et al., 2018)	110
6.4	Resultados para o cenário MEDIANET	113
7	Discussão	116
7.1	Discussão sobre o objetivo geral	116
7.2	Discussão sobre os objetivos específicos	118
7.3	Discussão final	120
8	Conclusão	123
8.1	Trabalhos futuros	124
8.1.1	Publicações Relacionadas	125
	Referências	127

1 Introdução

A Internet discada dos anos 1980/1990 com os históricos envolvimento sociais através dos *chats online* (KLEINA, 2017), causou um grande desejo, entre as pessoas, de Internet mais rápida. A evolução da Internet para banda larga dos anos 90 até os dias de hoje, possibilitando um leque de serviços cada vez mais especializados, proporcionou uma primeira experiência de serviços que necessitam de uma taxa de transferência maior. A adição do paradigma da Internet móvel, desde os anos 2000, com o uso de *smartphones* cada vez mais sofisticados e que possibilitam vários serviços na palma da mão (CIRIACO, 2009), traduziram a experiência da banda larga de maneira mais versátil. Redes sociais ou serviços de *streaming* de vídeo como *Netflix* já conseguiram apresentar para o público uma noção maior da necessidade de banda larga. Porém, nenhuma dessas evoluções conseguiram apresentar para o mundo uma noção, tão impactante, da importância de uma rede de transmissão de dados robusta e rápida como nos anos da pandemia de COVID-19, anos de 2020 e 2021.

Com as pessoas trabalhando de casa por causa do isolamento social em decorrência da pandemia do COVID-19, o tráfego de Internet aumentou (WIEDERHOLD, 2020). Esse tráfego de Internet também foi intensificado pelas empresas que modernizam seus serviços para se adequarem ao fechamento obrigatório das lojas e a consequente procura por produtos de forma *online*. O ramo de alimentação, por exemplo, funcionando basicamente por *delivery*, contribuiu para o aumento do tráfego de forma nunca antes feita por esse setor, já que as pessoas continuam sem tempo de cozinhar e não podiam ir aos restaurantes e, portanto, passaram a pedir as refeições de casa. Com as companhias promovendo vídeo conferências entre seus colaboradores, para não descontinuar suas atividades, houve um aumento na intensidade de tráfego de Internet, pois, os assuntos que eram discutidos de forma presencial passaram a depender de tráfego de rede rápida e robusta para serem tratados. Outras atividades humanas, também, causaram aumento no tráfego de Internet, como aulas sendo ministradas de forma remota, e, encontros familiares ocorrendo de forma *online* para se manter o distanciamento social. O tráfego de Internet de qualidade nunca foi tão requisitado em toda a história (LIMA, 2021; SCHEIFER, 2021).

Neste cenário as tecnologias de redes de transmissão de dados cumprem com um papel importante: ser rápida, eficaz, segura, funcional e de baixo custo. Dentre essas

tecnologias *Wavelength-routed optical networks (WRON)*, uma tecnologia de redes ópticas, se mostrou robusta e madura, e por isso, muito bem aceita entre os projetistas. Não é à toa que a infraestrutura da Internet é sustentada basicamente por redes ópticas. (RAMASWAMI et al., 2009; ARAÚJO et al., 2014; NASCIMENTO, 2017; TESSINARI et al., 2018).

As redes de comunicação de dados baseadas em fibra óptica tem vários aspectos técnicos que influenciam em suas características. Dentre esses aspectos técnicos está a topologia da rede de fibra óptica. Uma rede de fibra óptica, basicamente, é formada por nós terminais e enlaces ópticos, a topologia da rede é a maneira como os enlaces de fibra óptica interconectam esses nós terminais.

Fonte: O autor

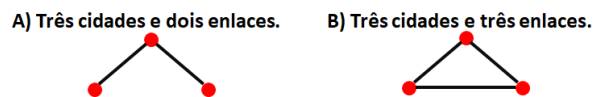


Figura 1 – Um exemplo simples e ilustrativo de duas topologias para uma única demanda de projeto de redes.

A Figura 1 representa duas topologias de rede. Na Figura 1 os círculos vermelhos representam os nós terminais e as linhas pretas representam os enlaces de fibra óptica ou *links*. Na Figura 1A há um projeto de topologia com dois enlaces interligando os três nós terminais, enquanto que, na Figura 1B há três enlaces fazendo a interconexão dos três nós terminais. O projeto da Figura 1A é um projeto mais barato, porém, é menos resiliente, o que significa que é menos robusto a falhas que o projeto da Figura 1B. Enquanto que, o projeto da Figura 1B é mais caro, todavia, é mais resiliente. Resiliência e custo são atributos de uma topologia de rede que podem ser medidos, respectivamente, pelas métricas de Conectividade algébrica e *CAPEX (Capital Expenditures)*. No exemplo da Figura 1, tem-se uma única demanda para dois projetos de topologia de rede, e, diferentes projetos de topologia de rede alteram diferentes características da rede.

O projeto físico de uma topologia de rede é chamado de *PTD (physical topology design)*. O PTD, além de outras questões técnicas como especificações de equipamentos dos nós terminais e dos tipos de fibra óptica que serão usados, também, tem que informar a topologia da rede óptica. A tarefa do PTD não é uma tarefa simples, visto que, o PTD é um problema combinatório *NP-hard* (CHAVES et al., 2010a; ARAÚJO, 2015; DUPLÉIX et al., 2016; NASCIMENTO et al., 2018).

Por ser um problema combinatório, o PTD é um problema passível de ser resolvido por algoritmos evolucionários *EA* (*evolutionary algorithm*). Um grande número de trabalhos vêm tratando o PTD usando algum tipo de EA (ARAÚJO et al., 2011; ARAÚJO et al., 2014; FIGUEIREDO et al., 2016; DUPLEIX et al., 2016; NASCIMENTO et al., 2018; BARBOSA et al., 2018). A maioria desses trabalhos fornecem como entrada para o algoritmo a localização dos nós terminais e têm como saída o conjunto de topologias e as respectivas especificações dos equipamentos ópticos a serem instalados nos nós terminais como o *ROADM* (*Reconfigurable optical add-drop multiplexer*), além do número de comprimento de ondas W . Todavia, em (NASCIMENTO et al., 2018), uma nova abordagem foi apresentada. A ideia levantada pelo trabalho é que a localização dos nós terminais é uma questão muito complexa para ser decidida sem otimização. Assim, foi proposto que a localização dos nós terminais passaria a ser uma variável de decisão do algoritmo e não mais um parâmetro de entrada.

Nascimento et al. (2018) usou, então, uma etapa de agrupamento dividindo as cidades do mapa da região, para onde o PTD seria atribuído, em grupos de cidades. A Figura 2A, mostra a saída da etapa de agrupamento e, conseqüentemente, a entrada da etapa de otimização.

Fonte: adaptado de (NASCIMENTO, 2017)




Figura 2 – O PTD proposto em um trabalho anterior: o benchmark principal dessa pesquisa - (NASCIMENTO et al., 2018).

Na Figura 2A, os quadrados pretos são as cidades centróides de cada grupo, os

triângulos mostram outras cidades dentro do grupo e o círculo que isola as cidades é a delimitação do grupo de cidades. As Figuras 2B e C mostram a visão da topologia em si, e, neste caso, os quadrados representam algo a mais, são as cidades que detêm o nó terminal da rede de transporte. Os triângulos azuis são as demais cidades no grupo, as quais, pelo projeto de Nascimento *et al.* (2018), seriam atendidas por rede de acesso, geralmente, usando tecnologia de custo mais acessível como redes *PON* (*passive optical network*) ou outra tecnologia. Já a Figura 2D mostra a visão da busca local, onde a delimitação mais interna, feita com o círculo vermelho, mostra a cidade que detém o nó terminal da rede de transporte (o quadrado) e as três cidades mais próximas da cidade detentora do nó terminal, as esferas vermelhas. O conjunto de grupos de cidades servem de entrada para a etapa de otimização. Os nós terminais iniciais da etapa de otimização são o conjunto de cidade centróide todo grupo de cidade tem uma cidade centróide, na Figura 2A, o conjunto de cidades centróides é o conjunto de todos os quadrados pretos. A sequência da Figura 2B para 2C, mostra a ação da etapa de otimização, onde a configuração da interligação entre os nós terminais, através dos enlaces de fibra óptica, vai mudando e proporcionando as mais variáveis topologias de rede.

Dessa forma, a localização dos nós terminais do PTD tratado por Nascimento *et al.* (2018), passou a ser uma variável de decisão do algoritmo, e não mais, uma variável de entrada como é comum no estado da arte (FIGUEIREDO *et al.*, 2016; DUPLEIX *et al.*, 2016). Contudo, a localização dos nós terminais continuava sendo otimizada na etapa de otimização através de uma busca local inserida no EA usado em (NASCIMENTO *et al.*, 2018), O *NSGA-III* (*Nondominated sorting genetic algorithm III*). Uma busca local é a inclusão de um procedimento que aplica conhecimento específico do problema ao fluxo do EA. A Figura 2D mostra um grupo de cidades do ponto de vista da busca local apresentada em (NASCIMENTO *et al.*, 2018). A busca local sorteia um dos grupos de cidade para atuar. Após o sorteio do grupo de cidade para atuação, a busca local calcula as três cidades mais próximas à cidade que, naquele momento, detém o nó terminal, também chamado de *POP* (*Point of presence*). Com as três cidades mais próximas determinadas, a busca local sorteia uma entre as três cidades mais próximas e transfere o POP de posição. A nova solução, então, passa por avaliação de aptidão e se dominar a anterior, as soluções são trocadas na população.

Fonte: O autor.

a) Exemplo de intervenção da busca local: antes da busca.



b) Exemplo de intervenção da busca local: depois da busca.



Figura 3 – Exemplo de funcionamento da busca local proposta em (NASCIMENTO et al., 2018).

A Figura 3 mostra a ação da busca local elaborada em (NASCIMENTO et al., 2018). Da Figura 3a para a Figura 3b o POP é trocado da cidade de Ouricuri para a cidade de Exu, o que mexe com comprimento dos enlaces e com isso no custo, além de abrir possibilidades para instalações de outros *lasers* e modificar o consumo energético.

Regra do *pivot* é o termo usado para descrever as regras de aplicação de uma busca local tanto para seleção de indivíduos na população quanto para investigação da vizinhança. Nascimento et al. (2018), conseguiu evidenciar que uma busca local é capaz de auxiliar a evolução de um PTD em um EA. Entretanto, Nascimento deixou claro, em (NASCIMENTO, 2017), que o custo computacional adicionado é oneroso, isso por causa da regra do *pivot* usada em (NASCIMENTO, 2017). A regra do *pivot* é aplicar a busca local em todos os indivíduos da população e desde o início das iterações. O único artifício usado no trabalho, para diminuir o custo computacional oriundo da busca local foi não investigar a vizinhança inteira.

A questão é que existem problemas que por natureza já são custosos, no caso do PTD, um de seus atributos mais importante é a disponibilidade de recursos para atender uma demanda de tráfego. Esse atributo tem sua qualidade medida por uma métrica chamada probabilidade de bloqueio (PB). A probabilidade de bloqueio é uma métrica que precisa de simulação para ser medida. A simulação de uma solicitação de demanda de tráfego, para medir a probabilidade de bloqueio, pode levar dez segundos ou mais, dependendo da qualidade da topologia de rede. Nas execuções do algoritmo em

([NASCIMENTO et al., 2018](#)), uma única execução do algoritmo tinha 228 mil avaliações de aptidão, o que acarretava em 228 mil simulações. A aplicação da busca local seguindo a regra do *pivot* do trabalho elevava esse número de simulações para o dobro, ou seja, 456 mil simulações. Um exemplo do impacto dessa abordagem é que uma simulação que durasse uma semana poderia durar quinze dias. Além do mais, mesmo que a questão do custo computacional não seja prioridade em alguma abordagem, por exemplo, em um PTD que não analise tráfego dinâmico, analisar outras propostas de regras do *pivot* pode trazer ganhos não só no tempo de execução como também em aspectos como a eficiência do algoritmo.

O trabalho atual investiga o impacto de diferentes abordagens de busca local para o problema de PTD de redes ópticas que considera a localização dos nós terminais como variável de decisão. Além da exploração de diferentes regras do *pivot*, esse trabalho pretende propor um melhoramento na busca local desenvolvida em ([NASCIMENTO et al., 2018](#)), apresentando assim, uma nova busca local. Uma outra proposta desse trabalho é apresentar uma estratégia de escolha de solução, em meio à população de soluções, para aplicar a busca local em um número de indivíduos menor do que o tamanho da população. Esse trabalho também apresentará uma nova busca local, que não causa custo computacional adicional relativo a uma nova avaliação de aptidão, e que tem potencial para ser estendida a outros problemas combinatórios parecidos com o PTD.

1.1 Delimitação do Tema

Uma busca local aplica um custo computacional extra ao melhorar uma solução. A questão é que a busca local modifica a solução e a partir do momento em que a solução é modificada ela é uma nova solução que não tem os valores de métricas que a qualificam calculados. Então, para que essa nova solução seja comparada com outras soluções é preciso passar por avaliação de aptidão para calcular os valores de suas métricas. Isso é uma questão difícil de lidar e que pode invalidar a estratégia, principalmente, quando se trata de problemas que já são computacionalmente custosos ([EIBEN et al., 2003](#)). O PTD é um exemplo de problema computacionalmente custoso, todavia, não se pode negar que a adição de uma busca local proporciona a descoberta de soluções melhores ([NASCIMENTO, 2017](#)). No entanto, se for considerado uma situação em que uma empresa tenha pouco

tempo para entregar um PTD, e que essa empresa use um sistema de recomendações de PTDs, se esse sistema usa uma série de sobreposições de estratégias custosas, esse sistema vai demorar demais para dar uma resposta, o que o invalida. Um sistema que precisa ser ágil e que requer muito tempo para calcular uma solução se torna uma ferramenta inútil. A delimitação do tema dessa pesquisa é abordar diferentes estratégias relacionadas ao conceito de concepção e aplicação de uma busca local, propondo assim, diferentes estratégias de uso da busca local sem que haja prejuízos ao tempo de execução do algoritmo, e nem à qualidade extra das soluções, que a busca local pode oferecer. O caso de estudo para esse tema foi o PTD, reconhecidamente um problema custoso ([NASCIMENTO et al., 2018](#); [NASCIMENTO et al., 2020](#); [DUPLÉIX et al., 2016](#)). Além disso, o estudo das diferentes estratégias de busca local, incluindo estudos sobre diferentes regras do *Pivot*, podem também ser aplicados futuramente em outros problemas que pertençam à mesma família do problema considerado nesta dissertação.

1.2 Problema de Pesquisa

A hipótese é que é possível usar um algoritmo evolucionário adicionado de uma busca local, para lidar com o PTD e obter os ganhos de uma busca local, sem invalidar o método por causa do custo geral do algoritmo.

Porém, em primeiro lugar é preciso entender como o problema do PTD é tratado por um EA. O PTD é um problema combinatório, onde dado um conjunto de nós terminais, o objetivo é retornar um conjunto de enlaces priorizando a melhora de determinados atributos. Esses atributos são qualificados por objetivos ou métricas. Neste projeto os objetivos são: Probabilidade de Bloqueio (PB); custo de implantação da rede (CAPEX); gasto energético e Conectividade Algébrica (CA). A PB é um número que varia entre 0 e 1 e representa a chance de uma solicitação de conexão não ser atendida por falta de recursos de rede. CAPEX é o valor de investimento financeiro com o custo dos equipamentos que compõem a rede, as fibras ópticas e o custo com a sua implantação, esse valor pode assumir números altos e é obtido em u.m. (unidade monetária) ([ARAÚJO, 2015](#)). O consumo energético em kW, é um valor que também pode assumir números altos e é o consumo dos equipamentos eletrônicos da rede. Por último a CA é um valor que pode assumir números altos e que representa uma métrica de robustez, a CA mede basicamente a facilidade que

se tem em dividir um grafo em duas partes disjuntas com a remoção de apenas uma aresta. Levando esse conceito para redes ópticas, a CA é uma métrica que mede a capacidade da rede de continuar em funcionamento com a falha de enlaces.


Para que um EA trate o problema do PTD é preciso fazer uma modelagem de forma que os recursos do algoritmo como Cromossomo, População e os demais, além dos operadores evolucionários possam lidar com o problema (LINDEN, 2008; EIBEN et al., 2003). A configuração de conexão entre os nós terminais, através de enlaces, de um PTD pode ser representada por uma matriz de conexão. A Figura 4A, mostra a matriz de conexão de uma topologia de redes em anel. Já a Figura 4B mostra a topologia de rede em si. Na Figura 4A a primeira linha e a primeira coluna mostram os nós terminais da rede. É possível observar que os mesmos quatro nós terminais estão tanto na primeira linha quanto na primeira coluna. Exceto as células que estão na primeira linha ou na primeira coluna, todas as outras células podem assumir três informações:

1. 1: há um enlace entre os dois nós.
2. 0: não há um enlace entre os dois nós.
3. x: a conexão, via enlace, não pode existir, seria inválida.

Por exemplo, na célula destacada por um círculo há o número 1, o que significa a existência de um enlace entre o Nó 1 e o Nó 4, como de fato é possível observar na Figura 4B, onde o *enlace a*, conecta os dois nós. A diagonal principal da Matriz está marcada com x, o que significa que o enlace não pode existir. O motivo é que a diagonal principal representa uma conexão entre um nó e ele mesmo. No PTD, tratado aqui, um nó não pode se conectar com ele mesmo. Além disso, a conexão neste trabalho é bidirecional, portanto, cada enlace serve tanto para transmitir como para receber dados, ou seja, a conexão é composta por um enlace de fibra óptica único e não dois enlaces. Por este motivo só é necessário usar a metade da matriz, ou da diagonal para cima ou da diagonal para baixo, pois, essas duas partes são espelhadas e representam a mesma informação. Observando a Matriz, Figura 4A, na parte superior à diagonal principal, pode-se concatenar as linhas, $l1, l2$ e $l3$, marcadas a direita da matriz, obtendo o a sequência de caracteres 101101. A sequência de caracteres 101101 marcada na Figura 4 como cromossomo resultante é um cromossomo binário perfeitamente tratável por um EA.

Além do Cromossomo resultante que representa a conexão ou não, através de enlaces de fibra óptica, entre os nós terminais da rede de transporte, neste trabalho, ainda

Fonte: o autor.



Cromossomo resultante: 101101

Figura 4 – Ilustrando o entendimento do problema: uma matriz de conexão para uma topologia de quatro nós terminais.

há mais duas informações concatenadas no final do Cromossomo resultante. A primeira é um número de zero a quatro que representa o ROADM utilizado no projeto e a segunda é o número máximo de comprimentos de onda que poderão ser usados na rede, que pode assumir um valor $W = \{4, \dots, 40\}$. Simulando, assim, a aleatoriedade da situação real, onde não se pode saber quantos canais irão estar livres no momento de uma requisição à rede (NASCIMENTO, 2017; NASCIMENTO et al., 2018; NASCIMENTO et al., 2020; FIGUEIREDO et al., 2016; DUPLÉIX et al., 2016; ARAÚJO, 2015). Dessa forma o cromossomo final é um cromossomo misto.

Assim o problema da pesquisa tratado nesta dissertação pode ser formalmente definido da seguinte forma:

No problema combinatório do PTD, dado como entrada, um conjunto de cidades $C = (c_1, c_2, \dots, c_n)$, onde serão instalados os nós terminais da rede de transporte, além de, uma matriz de tráfego, o objetivo é encontrar o subconjunto de cidades c , contido em C , através de um algoritmo de agrupamento, e também, um conjunto de enlaces ou *links* $L = (l_1, l_2, \dots, l_n)$, que conecta as cidades formando os PTDs.

1.3 Objetivos

Nesta seção serão apresentadas as perguntas da pesquisa, além do objetivo geral e os objetivos específicos.

- **Pergunta de pesquisa 1:** É possível oferecer soluções ao projetista de maior qualidade do que as soluções fornecidas pelas estratégias atuais quando um mesmo custo computacional, em termos de avaliação de aptidão, é fixado?
- **Pergunta de pesquisa 2:** É possível oferecer soluções de mesma qualidade que as

soluções fornecidas pelas estratégias atuais com um custo computacional menor, em termos de avaliações de aptidão?

1.3.1 Objetivo Geral

O objetivo geral desta pesquisa é apresentar um método, para uso da busca local, que melhore a qualidade das soluções oferecidas pelos métodos atuais sem aumentar o custo computacional geral da execução do algoritmo, relativo ao número de avaliações de aptidão no PTD. Dessa forma, foram investigadas diversas abordagens de regras do *pivot*, além de desenvolver uma busca local que ao ser usada não necessita recalcular a aptidão da solução. Como uma das buscas locais foi idealizada de forma que aproveitasse a avaliação de aptidão natural do EA, o objetivo geral também incluiu experimentar o casamento de mais de uma busca local sem que houvesse aumento no número de avaliações de aptidão para cada uma das buscas locais combinadas.

1.3.2 Objetivo Específico

Em busca de atingir o objetivo geral desta pesquisa, também, foram atingidos os seguintes objetivos específicos:

- Investigar e avaliar padrões para o comportamento da população de um EA no tratamento do PTD.
- Propor uma busca local que melhore a busca apresentada em ([NASCIMENTO et al., 2018](#)).
- Propor uma busca local sem custo adicional de avaliação de aptidão.
- Para deixar a abordagem mais genérica, propor uma busca local que tenha potencial de ser usada em outros problemas combinatórios parecidos com o PTD.
- Apresentar uma estratégia de seleção de indivíduos na população, para aplicação da busca local, quando a abordagem não permitir aplicar a busca local em todos os indivíduos.

1.4 Organização do texto

O restante desse trabalho está dividido em 7 capítulos. No Capítulo 2 é apresentada a revisão da literatura, onde são discutidas obras literárias relacionadas com este trabalho. No Capítulo 3 é apresentada a fundamentação teórica, onde os conhecimentos técnicos usados neste trabalho são detalhados de maneira organizada. No Capítulo 4 é apresentado a proposta deste estudo, detalhando de maneira profunda as inovações aqui tratadas. O Capítulo 5, traz a metodologia onde as configurações de *hardware* e *software*, além dos *frameworks* e do planejamento dos experimentos, são explicitados. No Capítulo 6 são apresentados os resultados. No Capítulo 7 é feita uma discussão geral, elucidando as questões mais peculiares dos experimentos e relacionando os resultados com os objetivos desse trabalho. Por Fim, o Capítulo 8 fornece considerações finais, levanta os pontos fracos e faz sugestões para trabalhos futuros.

2 Revisão da Literatura

Este trabalho investigou várias abordagens de busca local em algoritmos evolucionários, variado a regra do *pivot* e averiguando o impacto desta variação no problema do projeto físico de topologias de redes ópticas (PTD). Dessa forma, os trabalhos relacionados são divididos em dois grupos. O grupo de trabalhos que lidaram com o PTD e o grupo de trabalhos que lidaram com busca local.

2.1 Trabalhos relacionados com o PTD

Em (DURAN et al., 2011) Durán *et al.* propõe duas nova versões do algoritmo de construção de topologias lógicas GAPDELTA (*Genetic Algorithm to Provision the network and to Design the Logical Topology*). O GAPDELTA é um algoritmo que constrói topologias lógicas de rede que minimiza ao mesmo tempo o congestionamento da rede e a quantidade de recursos. As novas versões estão listadas abaixo:

1. IA-GAPDELTA (*Impairment Aware*) que inclui *Q-factors* a topologia virtual (AZODOLMOLKY et al., 2010).
2. SC-IA-GAPDELTA que é uma atualização do IA-GAPDELTA ou (*Simple Cognition*) IA-GAPDELTA. Essa última versão inclui em sua população inicial alguns indivíduos da população final da execução anterior.

Os 3 algoritmos incluem em sua população inicial três redes especiais. A primeira é uma rede otimizada para minimizar o congestionamento. A segunda rede especial imita a topologia física da rede. Uma última rede especial representa um grafo Hamiltoniano (CORMEN et al., 2009). A versão do algoritmo mais aprimorada do artigo, além dessas três redes, inclui na população inicial uma parte da população final de uma execução anterior. É o que o artigo chama de cognição. A entrada da meta-heurística são as topologias virtuais de redes especiais, já citadas. Alguns indivíduos retirados do final da execução anterior e mais um conjunto de topologias virtuais de redes criadas aleatoriamente. A saída do algoritmo são as topologias virtuais de rede otimizadas. Os experimentos concluem que, comparando as três versões do algoritmo, a versão que inclui cognição se mostra superior. Os autores concluem o trabalho destacando que a inclusão da cognição trouxe resultados melhores na construção de topologias lógicas de redes

transparentes.

Em (LIMA et al., 2016) Lima e Bastos-Filho propuseram uma nova abordagem para o operador de cruzamento no NSGA-II para o tratamento do PTD. O estudo comparou o tradicional operador uniforme de cruzamento e mais uma variedade de combinações entres operadores de cruzamento lógicos *booleanos* como OR, XOR e $\sim$ XOR. A entrada do algoritmo trabalhado no artigo foi a posição geográfica dos nós terminais, a matriz de tráfego e o algoritmo roteamento e associação de comprimento de onda (RWA). A saída foram as topologias de rede, as especificações dos equipamentos ópticos que teriam que ser instalados na rede. O operador linear e os operadores lógicos foram combinados em várias configurações para os experimentos. Além disso todos os experimentos foram realizados com e sem o operador de mutação, ou seja, variando as configurações.

As combinações de configurações foram: apenas operador uniforme, apenas operador OR, apenas o operador XOR, apenas o operador $\sim$ XOR. Além de mesclas como, operadores OR e XOR combinados, operadores OR e $\sim$ XOR combinados, operadores XOR e $\sim$ XOR combinados.

Como explicado anteriormente, todas essas combinações foram experimentadas com e sem operador de mutação. Os experimentos foram conduzidos propondo topologias para os nós terminais de duas redes: a NSFNet (uma rede com quatorze nós terminais nos Estados Unidos) e uma rede com trinta e quatro nós da Eslovênia. Os experimentos concluem que a abordagem é promissora, pois, os operadores NOR e XOR apresentaram valores similares ao operador uniforme, porém para a rede de quatorze nós, o tempo de execução foi menor em alguns cenários. Já o operador $\sim$ XOR mostrou resultados e tempo de execução melhor que o operador uniforme. Os autores concluem o artigo informando que trabalhos futuros podem avaliar outros operadores lógicos, podem usar a interseção em uma parte específica do grafo ao invés de no grafo inteiro. Podem usar a técnica nos nós terminais acerca de verificar a existência ou não de enlaces desejados.

Em (TESSINARI et al., 2018) Tessinari *et al.* fizeram experimentos em topologias de redes ópticas usando como objetivos probabilidade de bloqueio e taxa de transferência. Entretanto, o trabalho não usou uma meta-heurística. Invés disso, todas as possibilidades de topologias de rede como o número de nós entre quatro e sete foram geradas por

exaustão. Todavia, para controle de custo computacional, a pesquisa investigou apenas topologias sem equivalentes e que representassem grafos 2-conetados. As penalidades da camada física também não foram consideradas neste estudo. O artigo evidência que para cada número n de nós de quatro a sete, há apenas uma topologia que representa uma rede em anel e apenas uma outra topologia que representa uma rede totalmente conectada. A entrada da avaliação de Tessinari foi o conjunto de todas as possíveis topologias de rede ópticas que reaperntassem um grafo 2-conetados e sem equivalentes. A saída foi o conjunto de topologias avaliadas por faixa de carga de tráfego entre 200 e 400 erlangs. Os experimentos apresentam gráficos de linhas, onde as linhas representavam as redes ópticas entre a topologia em anel e a topologia completamente conectada, as quais, aparecem nas linhas extremas do gráfico. Os resultados relatam que entre a rede em anel e a totalmente conectada há uma diferença de 580% na probabilidade de bloqueio. Também concluem que, entre a rede em anel e a rede completamente conectada há várias redes com desempenho similar. Os resultados concluem ainda que, com baixo número de erlangs todas as topologias estudadas alcançaram a mesma taxa de transferência, visto que, até a topologia em anel tinha os recursos necessários para lidar com o baixo tráfego. Ao fazer uma comparação entre topologias com dez e quatorze enlaces, concluiu-se que há um ganho de até 73,9% em probabilidade de bloqueio e de até 17,3% na taxa de transferência nas redes de quatorze enlaces. Porém, há redes com quatorze enlaces que tem o mesmo desempenho de redes com 10 enlaces dependendo do número de erlangs. Os autores encerram o artigo enfatizando que, pelos resultados, ficou claro a influência significativa que a topologia tem na rede e deixam como estudos futuro a investigação em redes com uma quantidade maior de nós, ou usando tecnologias diferentes.

Em (BARBOSA et al., 2018), Barbosa, Sousa e Agra propuseram um método de construção de topologias de redes transparentes objetivando um bom compromisso entre custo e resiliência à falhas de larga escala. Primeiro o trabalho explica o que é um nó terminal crítico, relatando que nós desse tipo têm a capacidade de interromper a rede quando entram em falhas. Depois o artigo apresenta uma métrica chamada de *2-terminal reliability* (A2TR). Essa métrica considera a existência de nós terminais críticos em uma rede transparente para medir a resistência da rede a falhas de larga escala. A métrica A2TR é definida como o número de par de nós que continuariam conectados se todos os

nós críticos da rede entrassem em falha, e, esse conjunto de nós críticos fosse a solução ótima para o problema de otimização de detecção de nós críticos (CND). Após apresentar a métrica, o trabalho propõe um algoritmo guloso capaz gerar topologias de redes dado um conjunto de nós e um limite de comprimento geral de enlaces. Esse algoritmo é capaz de criar redes resilientes do zero ou de melhorar a resiliência de redes existentes através de adição de mais enlaces. Em ambos os casos o investimento é limitado a um dado comprimento de enlaces (controle de custo). Para experimentar a abordagem o estudo usou três redes reais *Germany50*, *PalmettoNet* e *Missouri Network Alliance (MissouriNA)* (BARBOSA et al., 2018). A modelagem dos experimentos foi criar uma topologia a partir de cada uma das redes reais acima citadas. As topologias criadas eram projetadas para serem resilientes a falhas de larga escala. As topologias criadas limitavam-se aos mesmos nós terminais e mesmo comprimento total de enlaces de cada uma das redes reais originais. Por fim, essas três topologias especializadas em resiliência seriam usadas como referência para aferir a lacuna de resiliência entre cada uma delas e a sua versão original. Adicionalmente as redes originais foram atualizadas primeiro com 10%, e depois 20% a mais dos seus respectivos comprimentos totais de enlaces. E as redes resultantes também foram usadas para comparação com as respectivas redes referência. As entradas da abordagem para os experimentos apresentados no artigo foram divididas em duas partes:

1. Para criar uma nova rede especializada em resiliência a partir das redes reais originais, para cada rede: os nós das respectivas redes originais e o limite de comprimento de enlaces que representava o comprimento total de enlaces da rede original.
2. Para atualizar, melhorar as redes existentes: a própria topologia da rede real e o limite de 10% do comprimento total de enlaces da rede original. Essa abordagem foi repetida com 20%.

A saída do item 1, foram as respectivas topologias de rede, especializadas em resiliência, geradas pela técnica. A saída do item 2 foram as topologias de rede originais atualizadas com 10% e 20% a mais de enlace. Os experimentos concluem que há uma lacuna de resiliência muito grande entre a rede criada com a técnica apresentada e a rede original. Concluem também que essa lacuna diminui quando as redes originais são atualizadas com mais enlaces, havendo, portanto, espaço para melhora de tais redes através da nova técnica. Os autores concluem o trabalho evidenciando que ficou claro que topologias com

uma distribuição do grau dos nós uniforme tendem a ser mais resilientes a falhas de nós críticos.

Os trabalhos relacionados com o PTD relatados nesta seção trazem uma visão geral de como o tema vem sendo amplamente investigado na literatura. Todavia, esses trabalhos não mostram preocupação com a questão do planejamento integrado entre a rede de transporte e a rede de acesso. Esses trabalhos também não mostram nenhum estudo de otimização da localização dos nós terminais, através de uma busca local, com foco no custo computacional que a busca local promove. Esse é o primeiro trabalho a promover um estudo do aspecto da otimização da localização dos nós terminais, focado na redução do custo computacional imputado.

2.2 Trabalhos relacionados com busca local

Em (ZHOU; WANG, 2014) foi proposto um algoritmo baseado em busca local para lidar com o problema de roteamento de veículos com janela de tempo (VRPTW), o *LSMOVRPTW*. Apesar de este artigo está sendo destacado em trabalhos relacionados por causa do uso da busca local, do ponto de vista computacional uma rota de veículos e um *layout* de um PTD são apenas grafos em aplicabilidades pragmáticas diferentes. O *VRPTW* pode ser descrito como um conjunto de clientes que têm que ser atendidos por uma frota de veículos que saem de um depósito central. As restrições para o problema são: cada veículo tem um limite de capacidade, cada cliente tem que ser servido por exatamente um veículo, por fim, cada cliente é associado a uma janela de tempo específica. O objetivo é criar uma rota de menor custo satisfazendo as restrições. O algoritmo usa buscas locais direcionadas para cada um dos objetivos e não usa operadores genéticos para evoluir a população. Ou seja, as próprias buscas locais são quem evoluem a população. Este trabalho usa os mesmos objetivos do problema formulado em (CASTRO-GUTIERREZ et al., 2011) que tem 5 objetivos conflitantes. A missão do algoritmo é minimizar esses cinco objetivos: O número de veículos, a distância total de viagem, o tempo de viagem da rota mais longa, o tempo total de espera e o tempo total de atraso (ZHOU; WANG, 2014). A entrada do problema é proveniente da base de dados proposta em (CASTRO-GUTIERREZ et al., 2011), que foi formulada a partir dos dados de uma

empresa espanhola de entrega de comidas. A saída do algoritmo é o conjunto de rotas de entrega. As métricas de aferição de qualidade foram a *Inverted generational distance (IGD)* (ZHANG; LI, 2007), que mede convergência e o *Hypervolume* (ZITZLER et al., 2001), que mede convergência e espalhamento. Também foi usado a métrica *Convergence metric* (ZITZLER; THIELE, 1999), que compara dois conjuntos de soluções não dominadas. Os experimentos comparam o algoritmo proposto com uma versão modificada do NSGA-II para trabalhar o VRPTW (CASTRO-GUTIERREZ et al., 2011). Os resultados dos experimentos mostraram que o *LSMOVRPTW* se saiu melhor que o NSGA-II para VRPTW, ao obter soluções não dominadas de melhor qualidade. Os autores concluem propondo como trabalhos futuros combinar o *LSMOVRPTW* com *tabusearch* ou incluir operadores genéticos e propor um algoritmo memético.

Em (ABOUHAWWASH et al., 2017) Abouhawwash, Seada e Deb, propuseram uma versão híbrida do NSGA-III. Uma versão híbrida de um algoritmo evolucionário tem uma busca local embutida (LINDEN, 2008). A estratégia da abordagem é aplicar a busca local sem que o custo computacional torne a junção da busca local com o algoritmo evolucionário, custosa demais e por isso inviável. O texto explica que a estratégia é escolher os indivíduos certos ao invés de aplicar a busca local em todos os indivíduos da população. Aplicar a busca em todos os indivíduos da população parece tentador, mas causa um custo excessivo ao algoritmo híbrido. O trabalho explica que em um conjunto de soluções baseados em algoritmos evolucionários, as soluções não dominadas estão mais próximas ao conjunto do Pareto real. Mas que sem nenhuma informação sobre o Pareto real fica difícil de estimar quais delas estão relativamente mais próximas entre si. A abordagem tem como objetivo identificar, entre as soluções não dominadas, qual delas está mais distante do Pareto real e aplicar a busca local nestas soluções. A pesquisa usa uma métrica derivada das *Karush Kuhn Tucker (KKT) conditions* para estimar a distância de cada indivíduo da população do Pareto real. As condições de *KKT* são as condições para dizer se uma solução para um problema de computação não linear é ótima. A questão é que tais condições são custosas de calcular e para resolver isso o trabalho usou uma métrica proposta em (DUTTA et al., 2013), a *KKTPM*. O artigo experimentou a abordagem em vários problemas clássicos da literatura (ABOUHAWWASH et al., 2017), fazendo uma comparação entre o NSGA-III clássico e a versão híbrida. A entrada

da abordagem foram soluções criadas aleatoriamente para cada problema clássico da literatura experimentado. A saída foram as soluções evoluídas. A comparação foi feita em termos da melhoria da métrica *KKTPM* e também de *Hypervolume*. A equiparação dos dois algoritmos foi em termos de avaliação de aptidão e não em termos de número de iteração para não haver injustiça. Os experimentos concluíram que a versão híbrida se saiu melhor nos experimentos, porém, com alguma perda de distribuição nas primeiras iterações. Os autores encerram o artigo abrindo espaço para que pesquisas tentem solucionar a questão da perda de distribuição inicial.

Em (MANSOUR et al., 2017) Mansour, Alaya e Tagina propuseram um novo algoritmo de busca local iterativo. O algoritmo usa vetores de pesos para transformar os M objetivos do problema em um único escalar, usando para isso, a função Chebyshev (MANSOUR et al., 2017). Para transformar os valores de objetivos de um problema multiobjetivo em um valor escalar é preciso atribuir pesos a cada um dos objetivos. A abordagem usa vetores de peso que vão gradualmente se modificando a cada iteração do algoritmo de acordo com uma frequência dada como parâmetro de entrada. O algoritmo foi testado no problema da mochila multiobjetivo. O problema da mochila descreve a tarefa de colocar objetos em uma mochila que tem pesos e valores diferentes. A mochila tem um limite de peso. O objetivo é maximizar o valor total dos objetos combinando-os na mochila sem exceder o limite de peso. O algoritmo não usa operadores genéticos para gerar descendentes na população, e ao invés disso, há um procedimento chamado perturbação que troca elementos da lista de objetos não pegos por um objeto aleatoriamente selecionado na mochila. A busca local proposta descobre a sua vizinhança através de uma métrica proposta no próprio trabalho chamada de razão de adição ponderada. O elemento dos itens não pegos que tiver o maior valor desta métrica é o primeiro candidato a substituir um dos itens da mochila escolhido aleatoriamente. A abordagem é experimentada usando como referência alguns algoritmos apresentados em trabalhos anteriores: MoMad (KE et al., 2014), o 2PPLS (LUST; TEGHEM, 2012) e o MOTGA (ALVES; ALMEIDA, 2007). As métricas usadas foram a diferença de *Hypervolume* e *Mann-Whitney statistical test* (KNOWLES et al., 2006), além do tempo computacional. A entrada da abordagem foram as instâncias de *benchmark* do problema da mochila multiobjetivo (ZITZLER; THIELE, 1999). A saída foram as populações

de soluções para o problema da mochila em cada um dos algoritmos. Os resultados dos experimentos apontaram que o algoritmo proposto se saiu melhor na maioria dos experimentos nas três métricas adotadas. Os autores terminam o artigo informando que trabalhos futuros podem experimentar diversificações dos parâmetros de entrada.

Em (NASCIMENTO *et al.*, 2018), um algoritmo memético com base no NSGA-III foi usado em uma nova abordagem para o problema do PTD, buscando otimizar quatro objetivos no PTD: Probabilidade de bloqueio, CAPEX, Consumo energético e Conectividade algébrica. Nascimento *et al.* (2018) usou um algoritmo de agrupamento, o *Kmeans*, e um algoritmo multiobjetivo o NSGA-III, com uma busca local. O *Kmeans* foi usado em uma etapa de pré-processamento, ou etapa de agrupamento, com a função de subdividir o mapa da região para onde as redes estavam sendo projetadas em grupos de cidades (a saber: o estado de Pernambuco). A etapa de agrupamento foi realizada com a intenção de transformar em variável de decisão um parâmetro que geralmente era dado como variável de entrada nos estudos anteriores levantados pelos autores, os nós terminais. O agrupamento foi feito por localização geográfica através de distância euclidiana. Como resultados, a etapa de agrupamento teve como saída os grupos de cidades e suas respectivas cidades centróides que serviriam como nós terminais iniciais para a segunda etapa da abordagem: a etapa de busca multiobjetivo. Após a etapa de agrupamento, iniciava-se a etapa de busca multiobjetivo sendo que a entrada dessa etapa era a saída da etapa de agrupamento, ou seja, os grupos de cidades e seus respectivos nós terminais. A etapa de busca multiobjetivo usando o algoritmo NSGA-III adicionado de uma busca local, trabalha as diversas topologias de rede ópticas da seguinte forma:

1. Inicialmente todas as redes da população são criadas usando como nós terminais as cidades centróides oriundas da etapa de agrupamento e interligando estas cidades através de enlaces criados aleatoriamente.
 2. Com o processo de evolução, o NSGA-III altera os enlaces em busca de otimizar os 4 objetivos citados anteriormente.
 3. Enquanto isso, através de um sorteio, um dos grupos de cidades é selecionado e a busca local, embutida no NSGA-III, altera a cidade onde é instalado o nó terminal em busca de soluções dominantes (essa troca é limitada a cidades do mesmo grupo).
- A busca local foi aplicada em todos os indivíduos da população e em todos os ciclos

do algoritmo, o que o autor deixa bem claro em (NASCIMENTO, 2017) que causa um aumento acentuado no custo computacional. De forma geral a entrada da técnica apresentada em (NASCIMENTO et al., 2018) foi o conjunto de localizações geográficas de todas as cidades da região onde a rede seria implantada mais o número K de nós terminais da rede, além da matriz de tráfego e o algoritmo de roteamento e associação de comprimento de onda (RWA). A saída foi um conjunto de redes sub-ótimas com as localizações dos K nós terminais, a configuração dos $\frac{K(K-1)}{2}$ enlaces de fibra óptica e as especificações de W e ROADM. Os experimentos comparam duas versões da técnica, onde uma continha a busca local, adicionada ao NSGA-III, e a outra não. O trabalho mostra através da métrica de *Hypervolume* que a abordagem com busca local foi superior. Os autores concluem o artigo enfatizando que a proposta foi capaz de acelerar a convergência e que novos estudos devem investigar diferentes estratégias de busca local assim como diferentes conjuntos de parâmetros de configuração do algoritmo.

Os trabalhos relacionados com busca local expostos nesta seção dão a exata noção de como o conceito é estudado, além de ser adaptável a vários problemas do mundo real. Entretanto, os trabalhos relacionados aqui presentes não mostram a preocupação em achar uma busca local que se estenda a mais de um problema combinatório pelo menos do ponto de vista da ideação. Também não mostram preocupação com os efeitos que teria a variação da regra do *pivot*. Apesar de que o problema da distribuição é tratado com outros operadores como o operador de seleção dos sobreviventes (DEB; JAIN, 2013), esses trabalhos não usaram uma busca local no auxílio da distribuição. Este é o primeiro trabalho a tratar a questão da distribuição da população como um problema a ser auxiliado por uma busca local. Como a questão da distribuição é comum a vários problemas combinatórios de múltiplos objetivos, a busca local apresentada, pelo menos do ponto de vista da ideação, é capaz de ser aplicada a mais de um problema combinatório. Este também é o primeiro trabalho a escolher o indivíduo, na população, como candidato ideal para aplicação de uma busca local em função da distribuição da população. A Tabela 1 resume o panorama geral sobre os pontos investigados nos trabalhos relacionados e os pontos investigados neste trabalho.

Tabela 1 – Tabela de nicho escolhido entre os trabalhos relacionados.

[illegible]

3 Fundamentação Teórica

Neste capítulo será fornecido o embasamento teórico de assuntos necessários para o entendimento da proposta do trabalho. Seja sobre aspectos relacionados ao problema (redes ópticas), quanto aspectos relacionados à solução proposta (algoritmos evolucionários).

3.1 Redes Ópticas

Nesta seção será apresentado alguns conceitos relativos a redes ópticas. A área de redes em geral é bastante vasta com vários tipos de forma de transmitir os sinais entre o emissor e o receptor. Todavia, o escopo desse capítulo será apenas referente aos conceitos necessários para o entendimento de redes ópticas.

3.1.1 Topologia de rede

Uma rede de fibra óptica tem várias características técnicas que são de extrema relevância para o seu funcionamento e desempenho. Essas características são mensuráveis como, por exemplo, custo, desempenho ou resiliência. Um dos aspectos técnicos, de uma rede óptica, que é capaz de exercer severas diferenças em várias dessas características técnicas é a topologia da rede (DUPLEIX et al., 2016; ARAÚJO et al., 2011; CHAVES et al., 2010a). Dado um conjunto de vértices $|V|$ e um conjunto de arestas $|E|$, um grafo $G = (V, E)$ é o conjunto de vértices $|V|$ interconectados pelas aresta $|E|$ (CORMEN et al., 2009). De forma mais geral, uma topologia de rede óptica pode ser vista como um grafo onde os enlaces de fibra óptica são as arestas e os nós terminais são os vértices. Ou seja, da mesma forma que um grafo, projetar uma boa topologia de rede óptica é um problema combinatório onde os nós terminais se interconectam de diversas formas possíveis através dos enlaces de fibra óptica. De forma mais específica uma topologia de rede envolve outras questões além do grafo $G = (V, E)$ ao qual ela representa. Há questões como, por exemplo, as tecnologias envolvidas tanto nos nós terminais como no nos próprios enlaces. A tecnologia é relevante pois influencia diretamente no custo e no alcance da rede. Os enlaces mais longos, os que compõem as chamadas redes de transporte ou *backbone*, geralmente, são construídos com a tecnologia que tem um alcance maior e,

portanto, são mais onerosas. Já os enlaces com distâncias menores (até 63 quilômetros) usam tecnologias com um custo bem mais acessíveis. O custo da rede é uma característica técnica importante, visto que pode inviabilizar um projeto. Na subseção seguinte será apresentado algumas dessas tecnologias.

3.1.2 Tecnologias de redes ópticas

Os enlaces de rede mais longos costumam usar tecnologias como as *WDM* - *Wavelength Division Multiplexing* ou *DWDM* - *Dense Wavelength Division Multiplex*. As tecnologias de *WDM* ou *DWDM* são conhecidas como tecnologias de redes ativas porque podem recuperar o sinal através de amplificadores. As tecnologias de *WDM* ou *DWDM* são mais caras pois tem um alcance muito maior sem que haja degradação excessiva do sinal. As tecnologias de longo alcance tem alcance mundial se houver repetição de sinal usando amplificares ópticos como um amplificador EDFAs ou RAMAN ([CHAVES, 2012](#); [GROUP, 2020](#)) . Esses amplificadores podem ser instalados em distâncias como de 80 em 80, de 100 em 100 quilômetros, a depender do projeto. Há várias formas de prover estrutura para o uso de amplificadores ao longo do enlace, como prédios ou contêineres sendo este último uma possibilidade de reduzir o custo do uso de amplificadores. Já para distâncias menores há tecnologias como *PON* (*passive optical network*) com alcance de 20 quilômetros ([HERON et al., 2008](#)) que é uma tecnologia de rede passiva. Um recurso estratégico para uma rede de acesso que precisa de uma distância um pouco maior entre os nós. O uso adequado dessas tecnologias é um recurso importante no controle de custos de uma topologia de rede, visto que existem as redes de transporte, que levam uma quantidade grande de dados por uma longa distância. Para as redes de transporte as tecnologias como *WDM* e *DWDM* justificam o investimento. Porém, também existem as redes locais ou metropolitanas que levam uma quantidade menor de dados para um concertador que está relativamente próximo. Para as redes locais uma rede *PON* já resolve bem o problema e com um custo bem menos elevado.

Outra arquitetura que vem sendo cada vez mais estudada para redes de longa distância são as Redes Ópticas Elásticas (EONs), que prometem o uso mais eficiente do espectro e algumas outras vantagens sobre rede *DWDM*. Na tecnologia EONs todo o espectro é dividido em slots de espectro e o cliente é atendido de acordo com a sua demanda

de espectro, ou seja, de acordo com a demanda é atribuindo um número suficiente de slots contíguos para cada cliente (CHATTERJEE et al., 2017). Contudo, as redes DWDM ainda correspondem ao cenário mais comum em redes de transporte comerciais e a proposta deste trabalho poderá ser replicada para redes EONs futuramente com adaptações.

3.1.3 Nós terminais

O nó terminal de uma topologia de rede, POP (*point of presence*) ou simplesmente nó da rede é um conjunto de equipamentos que de um lado emitem o sinal (nó emissor) e do outro recebe o sinal (nó receptor). Esses equipamentos fazem a multiplexação, demultiplexação e cross-conexão dos sinais ópticos. Dentre esses equipamentos existe o *OADM* (*optical add-drop multiplexer*) ou multiplexador de inserção/remoção óptica e o *ROADM* (*Reconfigurable optical add-drop multiplexer*), um *OADM* que tem a facilidade de poder reconfigurar remotamente a comutação do tráfego WDM. As rotas dos caminhos de luz são configuráveis, e estes nós é que são capazes de exercer a configuração das rotas dos sinais, e, se trabalharem em conjunto com amplificadores, também, são capazes de fazer a amplificação dos sinais. Em um projeto de topologia de rede uma importante estratégia de controle de custo é dividir a rede em rede de transporte, que usa *WDM* e *DWDM*, e, rede de acesso que usa *PON* e *CWDM*. É exatamente do nó terminal da rede de transporte que o sinal é distribuído para os nós locais que devem ficar nas redondezas do nó principal ou POP.

Fonte: adaptado de (REGIÃO, 2020)




Figura 5 – Mitigação de custos no projeto de redes ópticas através da variação de tecnologias: mescla de redes de transporte e redes metropolitanas.

A Figura 5, apresenta um exemplo desta divisão, onde a estrela é um nó terminal da rede de transporte e o quadrado é um nó terminal local. A linha contínua é a rede de transporte e a linha tracejada é a rede de acesso. O fluxo de dados sai dos nós terminais locais e vai para o nó terminal da rede de transporte que funciona como um concentrador, esse fluxo inicial ocorre pela rede de acesso. Então, o nó terminal da rede de transporte concentra todo esse fluxo de dados. O POP, então, utiliza a rede de transporte ou rede de *backbone*, que tem uma capacidade de transmissão e um alcance muito superior a rede de acesso, para transmitir esses dados para, ou, através de outros nós terminais da rede (NASCIMENTO et al., 2018).

3.2 Descrição das métricas de atributos do PTD

Uma topologia de rede possui atributos que a conceituam em relação a características técnicas que tornam a rede mais apropriada pra determinado objetivo almejado pelo projetista. Neste trabalho foram usados como atributos das topologias, e, conseqüentemente, como objetivos para o EA, as métricas de CAPEX, que qualifica o atributo de custo; a métrica de Probabilidade de bloqueio que qualifica o atributo da capacidade de atendimento a requisições de conexão; a métrica de Consumo energético que qualifica o atributo de eficiência energética da rede; e, por fim, a métrica de Conectividade algébrica que qualifica o atributo de robustez da rede. Esta seção irá descrever a composição e entendimento das métricas que classificam os atributos de topologia de redes aqui tratados.

3.2.1 Probabilidade de bloqueio PB

A probabilidade de bloqueio, que é uma métrica utilizada tipicamente em redes com tráfego dinâmico e que geralmente é estimada a partir de simulações, é a medida estatística que mede a capacidade da rede atender ou não uma solicitação de tráfego por disponibilidade ou falta de recursos da rede. Acontece que meios de transmissão de dados tem limitações físicas e se em dado momento esse limite já tiver sido alcançado e chegar uma nova demanda de solicitação de tráfego a rede não conseguirá atender a solicitação por falta de recursos físicos.

Sendo uma medida de desempenho da rede, a probabilidade de bloqueio PB, tem

que ser baixa para que uma rede seja mais apta a anteder as solicitações de tráfego. Uma maneira de aferir a PB é simulando uma alta demanda de requisições e depois comparar as solicitações totais de tráfego com as solicitações de tráfego que não conseguiram ser completadas por falta de recurso da rede. Desta forma, sendo sTT as solicitações totais de tráfego e sTB as solicitações de tráfego bloqueadas. A estimativa de PB pode ser representada pela Equação 3.1:

$$PB = \frac{sTB}{sTT}. \quad (3.1)$$

3.2.2 Investimento capital com a implantação da rede CAPEX

O CAPEX é o custo com os equipamentos que compõem a rede, as fibras ópticas e investimentos necessários para a sua implantação. O modelo de custo praticado nesta pesquisa foi o mesmo trabalhando em outros trabalhos do ramo como (NASCIMENTO, 2017; ARAÚJO, 2015). Abstraindo a questão das diferentes moedas existentes e adotando uma unidade genérica de custo (u.m - unidade monetária), os custos considerados são quatro:

1. Custo fixo com o comprimento de onda: o comprimento de onda está associado a um OLT (*Optical Line Terminal*).
2. O custo com a fibra óptica e a sua implantação.
3. O custo com os amplificadores de sinal óptico.
4. O custo com os ROADMs (*Reconfigurable optical add-drop multiplexers*).

O comprimento de onda tem um custo por estar associado a OLT (*Optical Line Terminal*) um equipamento de conversão de sinal óptico elétrico que trabalha entre os clientes e a rede translúcida (totalmente óptica). O custo é dado pela Equação 3.2.

$$COST_{\lambda} = 2 \cdot \eta \cdot w \cdot \sum_{i=1}^n D(i, i). \quad (3.2)$$

Onde:

- η : constante do custo com o OLT.
- w : Número de comprimento de onda para cada enlace.
- n : é a número de nós terminais da rede.

- $D(i, i)$: é o grau do i_{esimo} nó da rede.

O custo referente ao investimento com fibra óptica pode ser traduzido como o custo da compra da fibra óptica mais o custo com a sua implantação. A Equação 3.3, formaliza o custo com fibra óptica.

$$COST_{cable} = (\beta_{dcf} + \beta_{ssm} + \beta_{dcf} + \beta_{Dep}) \sum_{i=1}^n \sum_{j=i+1}^n d(j, 1). \quad (3.3)$$

onde:

- β_{dcf} : custo com fibras tipo DCF (*Dispersion Compensate Fiber*).
- β_{ssm} : custo com fibras tipo SSMF (*Standard Single Mode Fiber*).
- β_{dcf} : custo com implantação.
- $d(i, j)$: é a distância entre o i_{esimo} e o j_{esimo} nós.

A Equação 3.4 representa o custo com os amplificadores da rede.

$$Cost_{amplifier} = \delta \cdot \sum_{i=1}^{e_{max}} Camp(i). \quad (3.4)$$

onde:

- δ : é uma constante.
- e_{max} : é o número máximo de enlaces bidirecionais.
- $Camp(i)$: é o custo por unidade para um modelo de amplificador.

O custo com os comutadores ópticos administráveis, (gerenciáveis), é dado pela Equação 3.5.

$$COST_{ROADM} = C_{ws}(v_{k+}) \cdot \sum_{i=1}^n (\gamma_1 \cdot w + \gamma_2 \cdot D(i, i) + \gamma_3). \quad (3.5)$$

onde:

- C_{ws} : é o fator de isolamento do comutador.
- γ_1 , γ_2 e γ_3 : são constantes de adaptação do modelo a condição de mercado.

Somando estes quatro custos se obtém o custo geral de implantação da rede, (ARAÚJO, 2015; NASCIMENTO, 2017).

3.2.3 Consumo energético

Sejam comutadores, lasers ou amplificadores, por exemplo, muitos equipamentos funcionando na rede geram um consumo energético associado. Ao se mensurar o consumo em uma topologia de rede é preciso considerar todos esses equipamentos, sendo que a soma do consumo de todos será o consumo total da rede. As simulações de rede desse trabalho foram executadas no SIMTON - (Simulator for Transparent Optical Networks). Recentemente em (FIGUEIREDO et al., 2016), o SIMTON foi adaptado para incorporar o modelo de custo energético descrito em (HEDDEGHEM et al., 2012), onde consta que esse gasto energético é a soma dos itens da lista abaixo, (NASCIMENTO, 2017):

1. Chaveamento ou comutação de multiprotocolos e protocolos de Internet.
 - Uma camada IP / MPLS com roteadores associados.
2. Rede óptico de transporte (*optical transport networking* - OTN).
 - A camada OTN que trabalha na execução da multiplexação e transmissão por divisão de tempo.
3. Multiplexação por divisão de comprimento de onda (*wavelength division multiplexing* - WDM).
 - A camada WDM que trabalha na execução da multiplexação e transmissão por divisão espacial.
4. E por fim a camada de rede *ethernet*.
 - A camada de transporte.

Então, o consumo total é dado pela Equação 3.6.

$$P_{core} = P_{ip} + P_{ethernet} + P_{ont} + P_{wdm}. \quad (3.6)$$

Onde:

- P_{core} : é o consumo total da rede.
- P_{ip} : é o consumo com multiprotocolos e protocolos de Internet.
- $P_{ethernet}$: é o consumo com todos os equipamentos da camada de transporte.
- $+P_{ont}$: é o consumo com os equipamentos que trabalham com multiplexação por divisão de tempo.
- P_{wdm} : é o consumo com os equipamentos que trabalham com multiplexação por divisão espacial.

3.2.4 Conectividade algébrica - CA

A conectividade algébrica de uma topologia de redes ópticas é uma métrica de robustez da topologia. A robustez é um aspecto importante em uma topologia de redes de fibra óptica. Por exemplo, quanto mais encales para rotas alternativas tiverem uma conexão entre dois pontos quaisquer de uma rede, mais robusta essa conexão vai ser a uma falha que inviabilize um dos enlaces. A conectividade algébrica tem sua explicação no universo dos grafos. Supondo um grafo G qualquer, a matriz de adjacência de G , chamada de Matriz A , tem seus nós conectados quando $A_{i,j} = 1$. E, quando $A_{i,j} = 0$, os nós do grafo são não conectados.

Para esse mesmo grafo G a Matriz D é uma matriz $n \times n$ onde é exibido o grau dos nós. O grau dos nós é o número de conexões que cada nó tem com seus vizinhos. A matriz laplaciana é formada a partir das Matrizes A e D , como na Equação 3.7.

$$L = D - A. \quad (3.7)$$

A Conectividade algébrica é o segundo menor autovalor da laplaciana, $y_n - 1$. Quando $y_n - 1 = 0$, isso significa que o grafo em questão é um grafo desconexo. Portanto, altos valores dessa métrica indicam que o grafo tem em suas características um maior nível de dificuldade de ser separado em dois componentes, ao ser removido uma aresta (ARAÚJO et al., 2014).

3.2.5 Carga de tráfego em erlang

Erlang é uma unidade de tráfego usada em redes de dados que observa o fluxo de dados em um determinado período. Um erlang é a relação entre o tempo de duração de uma solicitação de conexão estabelecida e o tempo decorrente entre a conexão estabelecida e uma nova requisição de conexão. Ou seja, quanto menor o tempo decorrente entre uma requisição de conexão estabelecida e uma nova requisição de conexão, maior é a carga em erlangs. Todavia, quanto maior o tempo de duração de uma requisição de conexão estabelecida menor é a carga em erlangs (ARAÚJO, 2015; NASCIMENTO, 2017). A Equação 3.8 mostra a fórmula do erlang em função do tempo de observação e do volume

do fluxo de dados pelo tempo observado.

$$E = \frac{V_{fd}}{T_{ob}}. \quad (3.8)$$

Em que E é a carga em erlang e V_{fd} é o volume do fluxo de dados e T_{ob} é tempo observado. No SIMTON, simulador de redes ópticas usado nesta pesquisa, o fluxo de dados é modelado como um processo de Poisson (um modelo estatístico de aleatoriedade).

3.3 Algoritmos Evolucionários

Algoritmos Evolucionários (EA) são algoritmos de inteligência artificial que foram inspirados na evolução das espécies. Também chamado de meta-heurística para resolver um dado problema, começa com uma população de soluções criadas aleatoriamente. Então, as soluções são avaliadas e, geralmente, as avaliações iniciais são muito ruins. A partir da primeira avaliação acontecem as iterações de evolução, onde as soluções passam por mutação e cruzamento, gerando populações de soluções descendentes. Essas soluções descendentes são juntadas as soluções, a partir das quais elas foram geradas, e viram uma população única onde é aplicado uma seleção de sobreviventes para comporem a próxima geração.

Assim como na evolução natural dos seres vivos, onde apenas os seres mais adaptados aos seus respectivos ambientes, sobrevivem as adversidades da arte de viver. Nos algoritmos evolucionários apenas as soluções mais otimizadas, ou com as melhores avaliações, conseguem passar para gerações futuras (LINDEN, 2008). Os algoritmos evolucionários costumam ser bem adaptados a vários tipos de problemas combinatórios. Todavia, é necessária alguma abordagem na hora de modelar o problema para que seja executável por um EA. Para saber como lidar com o problema na hora de modelar é necessário se conhecer as estruturas e operadores de um EA. Portanto, conceitos como cromossomo, população, operador de inicialização, operador de avaliação de aptidão ou *fitness*, operador de *crossover* ou cruzamento, operador de mutação, iteração, condição de parada e operador de seleção dos pais são todos muito importantes para este estudo. Todavia, são conceitos básicos facilmente encontrado no estado da arte e, portanto, não serão apresentados aqui (EIBEN et al., 2003; LINDEN, 2008).

3.3.1 NSGA-III

Esta seção será explicado o algoritmo que é usado como fluxo principal do algoritmo proposto nesta pesquisa, o *Non-dominated Sorting Genetic Algorithm* III (NSGA-III) (DEB; JAIN, 2013). O NSGA-III é um algoritmo bastante usado no estado da arte para problemas com mais de 3 objetivos conflitantes. Com um fluxo semelhante ao do NSGA-II (DEB et al., 2002), o NSGA-III se difere do seu antecessor principalmente em função do operador de sobreviventes. O NSGA II foi concebido através de uma abordagem de ordenação de frentes de Pareto mais dinâmica que uma abordagem que o próprio (DEB et al., 2002) chama de ingênua. Deb descreve que uma abordagem ingênua consome uma ordem de $O(MN^3)$ comparações entre soluções para ordenar tais soluções em diferentes frentes de Pareto (no pior caso). Onde N é o número de soluções e M é o número de objetivos do algoritmo. No método do NSGA-II, primeiramente, são calculadas duas entidades, sendo p uma solução:

- (i) contador de dominação np que conta quantas soluções dominam p .
- (ii) conjuntos de soluções que p domina Sp .

Segundo (DEB et al., 2002), o cálculo dessas duas entidades é da ordem de MN^2 comparações. Após o cálculo dessas duas entidades, a frente de Pareto mais apta, ou o frente não dominada, é composta por toda solução que tiver o contador de soluções dominantes igual a 0, $np = 0$. Então, para cada solução que tenha contador de dominantes igual a zero, visita-se os membros do conjunto Sp , e diminui-se o contador de dominantes desse membro em um. Então, para cada membro q que ficar com np igual a zero, coloca-se este membro q em uma lista separada Q , pois este membro fará parte do segundo Pareto. Esse processo é repetido até que todas as frentes de Pareto sejam encontradas. Segundo (DEB et al., 2002), o pior caso da ordenação de frentes de Pareto no NSGA-II é da ordem de MN^2 comparações, o Algoritmo 1 mostra o procedimento do *fast non dominated sort* que é usado tanto no NSGA-II quanto no NSGA-III.

Sendo P uma população e p um indivíduo da população, onde, Sp é o conjunto de elementos dominados pelo indivíduo p e np o contador de soluções que dominam p , e também sendo q um outro indivíduo da população, $F1$ o conjunto de indivíduos que representa a primeira frente de Pareto e Fi o conjunto que representa uma outra frente i qualquer. E finalmente, sendo Q um conjunto temporário auxiliar a parte, usado em meio ao processo. Entre as linhas 1 e 15, a primeira frente de Pareto $F1$ é preenchida com

Algoritmo 1: fast-non-dominated-sort para o NSGA-II e o NSGA-III

```

1 for each  $p$  pertencente a  $P$  do
2    $Sp = \emptyset$ ;
3    $np = 0$  ;
4   for each  $q$  pertencente a  $P$  do
5     if  $p$  domina  $q$  then
6        $Sp = Sp \cup \{q\}$ ;
7     else if  $q$  domina  $p$  then
8        $np = np + 1$ ;
9   end
10  if  $np=0$  then
11     $p_{rank} = 1$ ;
12     $F_1 = F_1 \cup \{p\}$ ;
13  end
14 end
15  $i = 1$ ;
16 while  $F_i$  diferente de conjunto vazio do
17    $Q = \emptyset$ ;
18   for each  $p$  pertencente  $F_i$  do
19     for each  $q$  pertencente  $Sp$  do
20        $np = np - 1$ ;
21       if  $np=0$  then
22          $q_{rank} = i + 1$ ;
23          $Q = Q \cup \{q\}$ ;
24       end
25     end
26   end
27    $i = i + 1$ ;
28    $F_i = Q$ ;
29 end

```

todo indivíduo p se p não encontrar algum q que o domine. Na Linha 1 começa o *loop* mais externo dos dois *loops for* encadeados, ou primeiro encadeamento. O *loop*, iniciado na linha 1, realiza o mesmo ciclo de atividades para cada indivíduo p da população. Na linha 2, Sp , o conjunto de elementos que p domina, começa vazio. Na linha 3, o contador de dominantes de p começa zerado. Na linha 4, começa o *loop* mais interno, do primeiro encadeamento, que vai iterar em todos os indivíduos q , ou seja, indivíduos diferentes de p . Na linha 5, verifica-se a dominância de p sobre q , caso domine, q entra em Sp , linha 6. Na linha 7, verifica-se a dominância de q sobre p , e, caso domine, o contador de dominantes de p , np , é acrescido de 1, linha 8. Na linha 9, termina o primeiro *loop for* interno. Na linha 10, para cada elemento p da população P é verificado se o contador de dominantes está zerado. Se estiver zerado, significa que aquele elemento p da população não tem nenhum

elemento q que o domine. Então, na linha 11, o *rank* do indivíduo p é configurado como 1 e p é juntado a primeira frente de Pareto F_1 na linha 12. Na linha 14, acaba o primeiro encadeamento, é possível averiguar que além de fazer marcações importantes, o primeiro encadeamento basicamente preenche o primeiro Pareto da população. Na linha 15, o índice que identifica as frentes de Pareto é iniciado como 1, ou seja, a primeira frente. Então, o algoritmo irá começar o preenchimento das outras frentes de Pareto subsequentes. O *loop while*, que se inicia na linha 16, percorre cada uma das frentes de Pareto. Interno a esse *loop* há dois *loops for* encadeados. Para cada indivíduo $p \in F_i$ os dois *loops for* encadeados visitam todos os conjuntos S_p de soluções q dominadas por p . Na linha 17, o conjunto auxiliar Q é iniciado com um conjunto vazio. Na linha 18 começa os dois *loops for* encadeados. O primeiro *loop*, linha 18, itera sobre cada indivíduo p . Já o segundo *loop*, linha 19 itera sobre cada indivíduo $q \in S_p$. Na linha 20, cada indivíduo q tem seu contador de dominantes np decrescido de 1. Então, na linha 21 é verificado se o contador np do indivíduo q é igual a 0. Caso seja, significa que o indivíduo q pertence a próxima frente de Pareto e na linha 23, q é adicionado ao conjunto auxiliar Q . Na linha 27, o índice i que identifica a frente de Pareto é atualizado para a próxima frente F_{i+1} , e, na linha 28 essa nova frente F_{i+1} recebe o conjunto auxiliar Q . Esse procedimento é repetido até que todas as frentes sejam percorridas.

Ambos os algoritmos NSGA-II e NSGA-III usam este procedimento de ordenação de frentes de Pareto do Algoritmo 1. Mas diferente do NSGA-II, o NSGA-III usa um método de manutenção de espalhamento baseado em pontos de referência criados a partir do método de (DAS; DENNIS, 1998), o hiperplano normatizado. Com a população inicial criada, o NSGA-III cria esses pontos de referência e os usa iteração após iteração. Dessa forma o NSGA-III seleciona os indivíduos que mais se aproximam desses pontos referência como sobreviventes para a próxima geração. Então, O NSGA-III aplica os operadores genéticos como cruzamento e mutação e avalia toda a população gerada conforme o procedimento normal de um algoritmo evolucionário.

3.3.2 Torneio binário

O torneio binário é o operador de seleção dos pais que o NSGA-III usa. Este trabalho usa como algoritmo base o NSGA-III, além da abordagem para o PTD proposta

em ([NASCIMENTO, 2017](#)).

O torneio binário recebe uma população e uma lista vazia onde deve ser colocado as soluções da iteração vigente para serem pais das soluções da próxima iteração. A lista de pais deve ter o mesmo tamanho da população. Então, o operador de seleção dos pais sorteia duas a duas as soluções na população e coloca os pares em um torneio por dominância. Chamando as soluções sorteadas como $s1$ e $s2$ há três possibilidades nesse torneio de dominância.

1. $s1$ domina $s2$: $s1$ entra na população dos pais.
2. $s2$ domina $s1$: $s2$ entra na população dos pais.
3. $s1$ e $s2$ são não dominadas entre si: há um segundo sorteio entre as duas e quem ganhar no sorteio entra na população dos pais.

Porém há um momento em que a população toda entra em um Pareto único e quando isso acontece, o torneio binário vira praticamente um sorteio duplo, como nos passos abaixo ([NEBRO et al., 2015](#)).

1. O torneio binário sorteia duas soluções na população $s1$ e $s2$.
2. $s1$ e $s2$ são não dominadas entre si: há um segundo sorteio só entre as duas, e, quem ganhar no segundo sorteio entra na população dos pais.

No capítulo da proposta, Capítulo 4, será apresentado uma abordagem que irá tirar proveito dessa característica do sorteio duplo quando a população assume um Pareto único.

3.3.3 Operador de seleção dos sobreviventes

Existem muitos operadores que podem ser usados como operadores de seleção dos sobreviventes, tais como: seleção de roleta, amostragem universal estocástica, seleção de classificação linear, seleção de classificação exponencial, ([JEBARI; MADIIFI, 2013](#)). Contudo, quando o algoritmo é feito para problemas com muitos objetivos há dificuldades por parte do algoritmo com a questão da manutenção da diversidade da população. Um operador de seleção dos sobrevivente muito comum nos algoritmos evolucionários multiobjetivo (*MOEAs - Multiobjective evolutionary algorithms*) é o hiperplano normatizado que trata bem a questão da diversidade. O *NSGA-III*, algoritmo base dessa pesquisa usa o hiperplano normatizado, portanto, a nível de ilustração, o hiperplano normatizado será descrito nesta seção.

O hiperplano normalizado é o recurso do operador de seleção dos sobreviventes baseado na técnica de (DAS; DENNIS, 1998). O hiperplano normalizado é uma figura espacial de n dimensões, onde $n = M$, sendo que M o número de objetivos do problema. No hiperplano normalizado cada dimensão tem um eixo que representa os valores normalizados da função objetivo ao qual o eixo é associado. O hiperplano normalizado é igualmente inclinado para todos os eixos e contém pontos de referência que são distribuídos de maneira uniforme, através dos quais, o algoritmo preserva a diversidade das soluções. Por exemplo, se existe um problema com 3 objetivos, cada um desses objetivos pode ser representado em um plano cartesiano com três dimensões x,y e z (NASCIMENTO, 2017). Agora considere que cada um desses eixos terá p divisões ao longo de eixo, o número total de pontos de referência será obtido através de um arranjo simples demonstrado na Equação 3.9:

$$H = \binom{M + p - 1}{p}. \quad (3.9)$$

Como exemplo, pode-se citar o hiperplano para um problema de 3 objetivos, $M = 3$ e com cada eixo com 4 divisões $p = 4$. Nesse caso aplicando o arranjo simples $C_{n,p} = \frac{n!}{p!(n-p)!}$, o total de pontos é obtido como no exemplo da Equação 3.10.

$$H = \binom{3 + 4 - 1}{4} = \frac{6!}{4!(6-4)!} = \frac{5 * 6}{2!} = 15. \quad (3.10)$$

Ou seja, quinze pontos de referência, a Figura 6, mostra a projeção desses pontos em um problema de 3 dimensões.

Fonte: (NASCIMENTO, 2017), adaptado de (DEB; JAIN, 2013)




Figura 6 – Operador seleção dos sobreviventes especializado em distribuição: o hiperplano normalizado.

A partir desses pontos são traçadas retas que se cruzam e estes pontos de cruzamento

são a medida de espalhamento mais distribuída em todo o espaço finito de busca. Então, o operador de seleção dos sobreviventes escolhe para a próxima geração as soluções que mais se aproximam desses cruzamentos, mantendo assim um bom espalhamento como na Figura 7.

Fonte: (DEB; JAIN, 2013)




Figura 7 – Visão do espalhamento das soluções do problema clássico DTLZ1 resolvido pelo NSGA-III.

A Figura 7 mostra a solução do problema clássico da literatura DTLZ1, na Figura 7, cada esfera é uma solução e as soluções são escolhidas por se aproximarem dos cruzamentos de retas que marcam os pontos de melhor espalhamento. Quanto mais próximo dos cruzamentos de retas, maiores são as chances de a solução obter êxito na seleção de sobreviventes.

3.3.4 Operador de busca local

O operador de busca local é algo muito particular do problema e do especialista que o projetou, visto que, um operador de busca local é apenas a aplicação de conhecimento específico do problema ao EA. Um EA híbrido, ou um EA com um processo interno embutido, sendo que esse processo corresponde a conhecimentos específico do problema ao qual o EA está tratado, também é chamado de algoritmo memético. Um algoritmo memético é um EA com uma busca local inserida (NASCIMENTO, 2017; LINDEN,

2008). Segundo (LINDEN, 2008), a busca local é um procedimento que implementa conhecimentos específicos do problema. Com isso a busca local concede aos membros da população melhorias e os torna soluções melhores. (LINDEN, 2008) demonstra que geralmente o procedimento de busca local é inserido antes do operador de seleção dos pais, o Algoritmo 2 mostra a inserção da busca local.

Algoritmo 2: EA com busca local (LINDEN, 2008)

```

1 T:=0; ; // Inicialize o contador de tempo
2 Inicializa População P(0); // Inicialize aleatoriamente
3 Avalie População P(t); // Avalie a população neste instante.
  /* Condição de termino */
4 while Não terminar do
5   Aplique o operador de otimização local; // procedimento de busca local
6   P' = Selecciona Pais P(t); // Seleção dos pais
7   P' = Recombinação e mutação P' ; // Aplique os operadores genéticos
8   Avalie População P'; // Avalie esta nova população
9   P(t+1) = Selecciona sobreviventes P(t), P'; // Seleção de sobreviventes
10  T:=t+1; ; // Incremente o gerador de tempo
11 end

```

O procedimento de busca local é um refinamento de uma solução. A busca global em si, também chamada de *exploration*, é uma busca com um foco maior para uma exploração mais agressiva no espaço de busca finito. A busca global visa expandir os espaços inexplorados, ampliar o horizonte para outras soluções mais longínquas. Por outro lado, o processo de busca local, também chamado de *exploitation*, é focado em soluções mais próximas, mas parecidas com a solução atual, mas que por um detalhe ou outro a mais, consegue uma avaliação de aptidão melhor. O Algoritmo 2 mostra um EA com o procedimento de busca local.

A busca local pode ser aplicada de várias formas nos membros da população, como em um número x de membros da população ou a partir de uma determinada iteração do EA, ou ainda na população inteira, entre outras abordagens. Como a aplicação da busca local pode implicar em melhoria da população, aplicar a busca local em todos os indivíduos da população parece algo tentador (ABOUHAWWASH et al., 2017). Todavia, aplicar a busca local em toda a população implica em um custo computacional extra, relacionado a uma consequente reavaliação de todas as soluções da população, que pode tornar a estratégia cara demais em termos de custo computacional (LINDEN, 2008).

A linha 4 do Algoritmo 2 mostra a chamada para a busca local em uma abordagem onde a regra do *pivot* (detalhada na Subseção 3.3.5) seria aplicar a busca local em todo indivíduo da população. O Algoritmo 3 é um algoritmo chamado no meio do procedimento do Algoritmo 2. O Algoritmo 3 mostra na Linha 4 a comparação entre os valores de aptidão do indivíduo x , em que a busca local foi aplicada, e um indivíduo novo X' . O indivíduo X' foi gerado a partir de uma modificação feita pela busca local no indivíduo x . É possível observar, na linha 4 do Algoritmo 3, que a comparação é feita entre os valores de $f(x)$ e $f(X')$. No exato momento em que o algoritmo 3 faz essa comparação o valor de $f(x)$ já existe e ele é oriundo da iteração anterior do EA. Todavia, o valor de $f(X')$ não existe, pois o indivíduo X' surgiu na linha 3 do Algoritmo 3, ou seja, é um indivíduo novo que precisa passar por uma avaliação de aptidão antes de ser comparado com quem quer que seja. Se a regra do *pivot* for definida como a aplicação da busca local em todos os indivíduos da população, o custo computacional dobra o que para problemas custosos pode tornar a estratégia inviável. É importante investigar diferentes regras do *pivot* que possam aproveitar o melhoramento que uma busca local pode incluir sem se exceder em termos do custo associado da busca local.

Algoritmo 3: busca local (LINDEN, 2008)

```

1 while houver vizinhança do
2   Aplique o operador de busca local em x;
3    $X' = x$ ; //  $X'$  recebe x após passar pelo operador de busca local
   /* para um problema de maximização */
4   if  $f(X') \geq f(x)$  then
5     | Interrompa a aplicação do operador;
6   end
7 end

```

3.3.5 Regra do *pivot*

Como citado na subseção 3.3.4, a busca local, ou *exploitation*, é um procedimento que não pretende achar soluções longínquas da solução atual. Em outras palavras a busca local procura melhorias em soluções vizinhas a solução atual. A regra do *pivot* é a regra que determina como a exploração dessa vizinhança vai acontecer. No Algoritmo 3 a linha quatro determina que o algoritmo interrompa o procedimento de busca assim que achar

uma solução que incremente alguma melhoria. Contudo, é importante entender que nem toda solução vizinha fornece essa melhoria, o que pode causar um custo computacional muito grande ao se vasculhar a vizinhança inteira. A Figura 8, mostra um exemplo de soluções em um espaço de busca com três máximos locais e um máximo global, onde, os círculos são as soluções atuais e os quadrados são as soluções vizinhas. Na Figura 8, as soluções se concentram no Máximo global e no Máximo local 2. Para um problema de maximização, quanto mais próximo do ponto mais alto, dos máximos, uma solução tiver melhor. Na situação fotografada, na Figura 8, a solução $s1$ situada no Máximo local 2 tem dois vizinhos $v1$ e $v2$.

Fonte: o autor.




Figura 8 – Visualização de vizinhança de uma solução, máximos locais e máximos globais em um problema de maximização.

É possível observar que só a solução vizinha $v1$ oferece mais proximidade ao cume do Máximo local 2, portanto, só a solução vizinha $v1$ oferece melhoria enquanto a solução vizinha $v2$ não. Alguns problemas são muito custosos pois exigem simulação para se realizar uma avaliação de aptidão. A questão é que para saber se uma solução vizinha é melhor que a atual, será necessário avaliá-la para depois fazer a comparação (EIBEN et al., 2003). Se o procedimento de busca local, quando aplicado a $s1$ da Figura 8, encontrar primeiro a solução $s2$ que não oferece melhoria, o custo total para achar a melhoria em $s1$ vai dobrar. É possível observar que o Algoritmo 2 chama, na linha 5, a busca local para cada uma das soluções na população. Enquanto o Algoritmo 3, só para de aplicar a busca local quando encontrar uma solução melhor, ou seja, explora toda a vizinhança.

Supondo que em uma dada execução E de um algoritmo memético, tenha 400 indivíduos na população e que cada indivíduo tenha 10 vizinhos, cada iteração da execução E , pode causar um incremento de até 4 mil avaliações de aptidão a mais, no pior caso. A regra do *pivot* da execução E , seria então, aplicar a busca local em todos os indivíduos da população, e, para cada indivíduo explorar a vizinhança inteira.

Resumindo, a regra do *pivot* carrega a configuração da aplicação da busca local. A Tabela 2 mostra algumas possibilidades de configuração para aplicar uma busca local, na Tabela 2 a primeira coluna, ou Iteração de início, mostra como o início da aplicação da busca local pode ser configurado. Dependendo do problema que o EA está tratando essa configuração pode influenciar na mitigação da questão de máximos locais ao evitar aplicar a busca local logo no início das iterações, todavia, por outro lado aplicar a busca local logo no início pode gerar soluções boas de forma rápida.

Tabela 2 – Tabela de possibilidades para regras do *pivot*

Iteração de início	Número de vizinhos	Exploração da vizinhança	nº de indivíduos modificados pela busca local a cada iteração
20	3	Sorteie um vizinho e explore apenas ele	4
120	4	Explore a vizinhança até encontrar uma solução melhor	8
220	5	Explore toda a vizinhança em busca da melhor solução	12

A segunda coluna, ou Número de vizinhos, aplica um controle de custo importante ao delimitar o tamanho da vizinhança, em alguns problemas, a definição do que é um vizinho pode habilitar uma grande variedade de soluções definidas como vizinhos, portanto, é preciso delimitar um escopo ou o custo computacional poderá se elevar em uma possível investigação da vizinhança. A terceira coluna, ou Exploração da vizinhança, mostra como pode ser configurado a forma de verificar a vizinhança, o que também pode gerar custo computacional elevado, mas que por outro lado também pode trazer soluções mais

vantajosas ao se explorar o que há de melhor entre os vizinhos. Por fim a última coluna mostra as possibilidades de quantidade de indivíduos na população que irão passar pela aplicação da busca local a cada iteração, o que levanta outra questão que seria como selecionar esses indivíduos, mas isso também já seria outra regra do *pivot*.

Ou seja, tudo gira em torno de estratégias que possam melhorar a qualidade das soluções na população sem que haja custo computacional excessivo. Por exemplo, supondo que em uma execução de um EA para resolver um dado problema o critério de parada seja de 500 iterações e que as regras do *pivot* aplicadas nesta execução estejam na primeira linha da Tabela 2. Na primeira linha, a aplicação da busca local começa a partir da iteração 20 de um total de 500, ou seja, em uma iteração muito próxima do início o que pode aumentar o custo ou causar prisões em máximos locais (LINDEN, 2008), mas que também pode trazer soluções boas. Todavia a vizinhança foi delimitada a apenas três vizinhos, mesmo que existam mais, o que já impõe um certo controle no custo computacional, mas que pode prejudicar a busca ao não permitir que sejam encontrados vizinhos melhores que possam existir em uma possível vizinhança maior. O número de indivíduos que devem passar pela busca local também foi reduzido, o que também mitiga custo.

Se a segunda e a terceira linha da Tabela 2 forem observadas, será possível ver que algumas configurações são ampliadas, o que ampliar o espaço de busca local ou refinamento, mas que aumenta o custo computacional, entretanto, outras configurações são reduzidas o que mitiga custo, mas pode atrapalhar a busca local. A combinação das possibilidades de configuração dadas como exemplo na Tabela 2, ou de outras possibilidades que possa vir a ser definidas pelo projetista, trazem as diversas configurações de regra do *pivot*.

Por exemplo, em (NASCIMENTO et al., 2018), a busca local foi aplicada a toda a população, todavia, o trabalho controlou o custo computacional não averiguando toda a vizinhança, e sim, apenas um dos vizinhos. Resumindo, o autor preferiu parar a averiguação da vizinhança e perder a investida da busca local, caso o primeiro vizinho a ser investigado não fosse uma solução melhor, a elevar o custo computacional ainda mais investigando os demais vizinhos. Mesmo assim, tal abordagem dobrou o custo computacional da execução do algoritmo. Em (ISHIBUCHI; MURATA, 1998) também é usado a mesma abordagem de não investigar a vizinhança toda. Em (ABOUHAWWASH et al., 2017) há aplicação da busca em parte da população de acordo com uma análise das soluções em função de uma estimada proximidade ao Pareto real. Todas as possíveis variações de regra do *pivot*

tem uma possibilidade de ter atenção com o custo computacional, sem que haja perda das vantagens que a busca local pode trazer.

3.3.6 Hypervolume

Todo problema tratado por um EA tem a missão de atingir a convergência que é quando o algoritmo atinge soluções consideradas boas. Todavia, como citado na Subseção 3.3.3, quando um EA trata um problema multiobjetivo tem um desafio a mais que é a questão da diversidade da população. A população de soluções bem diversificadas proporciona variedade nas formas de solução do problema. Proporcionando assim uma ampla gama de opções de soluções para que um projetista tenha diversas opções de solucionar um projeto. Uma métrica revolucionária na área de algoritmos evolucionários é o *hypervolume*, abreviatura HV, que é uma métrica capaz de medir ao mesmo tempo a questão da convergência e da distribuição.

Usada para medir, de forma aproximada, a área destacada no gráfico da Figura 9, o *hypervolume* proposto em (ZITZLER; THIELE, 1999) é uma métrica que mede a convergência e a distribuição simultaneamente. A área entre ponto w e a curva varia de acordo com a convergência e a distribuição das soluções. Ou seja, quanto maior o *hypervolume*, que nesta pesquisa é um número que varia entre 0 e 1, mais bem convergida e mais bem espalhada está a população. O *hypervolume* desta pesquisa é um número que varia entre 0 e 1 porque os valores de métrica foram normalizados entre 0 e 1, portanto, a área da Figura 9 pode ser no máximo igual a 1. A normalização foi feita utilizando valores extremos de objetivo mesmo que esse valor fosse obtido de redes teóricas, por exemplo, a menor topologia seria de uma rede em anel e uma rede *full* conectada seria o maior.

Fonte: (ARAÚJO, 2015).




Figura 9 – Área do *hypervolume* em um problema de minimização com os objetivos normalizados entre 0 e 1.

4 Proposta

Este capítulo descreve a proposta deste trabalho, ou seja, as abordagens investigadas para o PTD de redes ópticas considerando a localização nos nós como variável de decisão. As abordagens estudadas partem desde estratégias de seleção de indivíduos até criação de buscas locais com o custo baixo. Este capítulo também formaliza o problema do PTD, ao qual, as abordagens estudadas neste documento foram experimentadas. Uma das técnicas aqui experimentadas, foi criada com a intenção de que possa ser adaptada para mais problemas combinatórios semelhantes ao PTD. Este trabalho examinou duas técnicas híbridas de EA com buscas locais e, uma terceira abordagem que é uma junção das primeiras duas técnicas. Este trabalho, ainda, experimentou estratégias de seleção de indivíduos para aplicar a busca local e as experimentou no PTD. Das buscas locais a primeira é para o PTD, o problema desta dissertação, que foi inspirada na busca local trabalhada em (NASCIMENTO *et al.*, 2018). Todavia, a busca local proposta aqui, diferente da busca local de Nascimento *et al.* (2018) também influencia a robustez da rede, que neste trabalho é representado pela conectividade algébrica. A segunda busca local foi idealizada para oferecer o potencial de ser aplicada a outros problemas que possuam características semelhantes ao PTD, o problema específico tratado pela segunda busca local é o problema da distribuição da população. A segunda busca local manipula uma fatia da população dos pais no momento que o Pareto populacional é único observando características de distribuição da população. Ou seja, a segunda busca local é focada em espalhamento e em conjunto com a primeira busca gera uma melhora tanto da distribuição como na convergência das soluções, o que gera a terceira abordagem de busca local que é uma fusão das duas primeiras. No final deste capítulo, após todos os conceitos aqui desenvolvidos terem sido elucidados, uma versão híbrida do NSGA-III, que sintetiza todas as técnicas aqui criadas, será apresentada.

4.0.1 Representação técnica do problema do PTD

Este trabalho lidou com o problema do PTD da seguinte forma. Dado, como entrada, um Super conjunto de cidades $C = (c_1, c_2 \dots c_n)$ e suas, respectivas, localizações geográficas, uma matriz de tráfego, com uma carga em erlangs associada, e o algoritmo de

associação de roteamento de caminhos de luz (RWA). O objetivo é encontrar o subconjunto de cidades c , contido em C , através de um algoritmo de agrupamento. E também, um conjunto de enlaces, aqui chamados de *links* $L = (l_1, l_2 \dots l_n)$, usando o algoritmo Genético de busca multiobjetivo, que interconecta estas cidades formando os PTDs. Adicionalmente, na etapa de definição de L , utilizar-se de busca local, para fazer pequenas modificações na localização do nó terminal, modificando c no intuito de achar soluções dominantes. Como último passo a busca local acrescenta um enlace a mais, entre dois nós da rede, escolhidos de forma aleatória.

A proposta da abordagem foi de simultaneamente, nos PTDs, minimizar a probabilidade de bloqueio PB, minimizar o custo da topologia de rede CAPEX, minimizar o consumo energético em Kilowatt e maximizar a conectividade algébrica CA. Com a restrição única de que toda topologia de rede representasse um grafo conexo, o que significar $CA > 0$. Usando o simulador SIMTON (CHAVES et al., 2010b), através de simulações de Monte Carlo, foi provido a probabilidade de bloqueio PB. O SIMTON é um simulador de redes transparentes que é capaz de calcular a probabilidade de bloqueio de redes ópticas através de tráfego dinâmico e incluindo considerações sobre as penalidades da camada física. Para os experimentos, deste trabalho, os valores dos objetivos (termo técnico para os EAs), ou valores de métricas de atributos da rede, foram normalizados para ficarem entre 0 e 1. Um detalhe muito importante é que os objetivos eram naturalmente um problema de minimização, exceto a conectividade algébrica. Para que o EA tratasse o problema como um todo, sendo o problema de minimização, a conectividade algébrica CA, foi traduzida como $CA_i = \frac{1}{ca+1}$, (CA inversa), na qual quando $CA_i = 1$, implica que $CA = 0$ e o PTD era um grafo desconexo (e portanto inválido conforme a restrição).

As variáveis de decisão foram:

1. A posição geográfica dos nós terminais da rede de transporte latitude e longitude.
2. O layout da topologia, ou a interconexão dos enlaces.
3. O número de comprimento de onda, ou canais, por enlace.
4. O ROADM selecionado, ou seja, o multiplexador óptico configurável selecionado.

A posição geográfica dos nós terminais foram representados por coordenadas cartesianas $P = (x_i, y_i)$ onde $i = \{1, ..n\}$ e n foi o número de nós terminais dados

como entrada. A Matriz 4.1 é a representação da matriz de adjacências.

$$\begin{pmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,n} \\ a_{2,1} & a_{2,2} & \dots & a_{2,n} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ a_{n,1} & a_{n,2} & \dots & a_{n,n} \end{pmatrix} \quad (4.1)$$

A matriz é dada por $\frac{n(n-1)}{2}$, pois, as possibilidades de interconexão por enlaces são de $n(n)$, onde n é o número de nós terminais da rede de transporte. Exceto por um nó, pois, como detalhado na Seção 1.2 nas explicações da Figura 4, qualquer nó não pode se conectar a ele mesmo. Dessa forma, o número de conexões possíveis passa a ser então $n(n-1)$. Como o enlace é bidirecional, toda conexão entre $a_{i,j}$ e $a_{j,i}$ é única, o que reduz o número de conexões possíveis pela metade. Ou seja, as conexões precisam ser representadas, apenas, na metade da matriz de conexões como explicado na Figura 4, então, a quantidade de conexões possíveis fica em $\frac{n(n-1)}{2}$. Os elementos da matriz são descritos como $(a_{ij} \in \{0, 1\})$, onde $a_{ij} = 0$ significa que o nó i e o nó j são não conectados e $a_{ij} = 1$, significa que são conectados.

A concatenação de todas as informações do modelo de tratamento resulta no vetor de representação da rede que é definido como $\vec{X} = \{x_i\}$ onde $(i \in 1, 2, 3, \dots, K + 2)$ em que $K = N + \frac{(N^2-N)}{2}$, onde N são os nós terminais da rede de transporte. Finalmente, os dois últimos parâmetros a entrarem no final do vetor são as especificações de ROADM $\delta = x_{k+1}$, e o número de largura de ondas $W = x_{k+2}$ em que w_{min} é o número mínimo e w_{max} é o número máximo de largura de ondas (NASCIMENTO, 2017); (FIGUEIREDO et al., 2016); (DUPLÉIX et al., 2016). A descrição matemática do problema do PTD é dada como o vetor, onde $\vec{X} = [P_1..P_n \quad a_{1,2} \quad a_{1,3}..a_{n-1,n} \quad \delta \quad w]$ é o vetor de representação que busca alcançar topologias que, simultaneamente, minimizem a PB, o CAPEX, o Consumo energético e a CA, condicionado a um grafo conexo $g(\vec{X}) = CA > 0$.

Descrição do problema: dada as variáveis de decisão, temos que.

$$\vec{X} = [P_1..P_n \quad a_{1,2} \quad a_{1,3}..a_{n-1,n} \quad \delta \quad w]$$

$$\text{minimize } x = \begin{cases} f1(\vec{X}) & = PB \\ f2(\vec{X}) & = CAPEX \\ f3(\vec{X}) & = \text{Consumo energtico} \\ f4(\vec{X}) & = \frac{1}{1+ca} \end{cases} \quad g(\vec{X}) = CA > 0$$

4.1 Proposta deste estudo

A proposta desse projeto se traduziu em uma investigação de diversas abordagens de regras do *pivot* operando em duas buscas locais e na mescla delas duas, o que formou uma terceira busca local, sobre o problema do PTD. As duas buscas locais são para o PTD, mas, uma delas tem potencial de se estender a outros problemas parecidos com o PTD. O mecanismo de uso das buscas locais, nesta proposta, foi configurado como um acionamento para um procedimento externo ao NSGA-III para os quais a sua chamada foi inserida no fluxo do algoritmo NSGA-III, o que transforma o NSGA-III em uma versão híbrida. A busca local para o PTD foi baseada na busca local de ([NASCIMENTO, 2017](#)) e foi modificada para incluir um maior espaço de busca para a métrica de Conectividade algébrica resultando em uma nova busca local, a BLVMD (Busca Local em Vizinhos por Menor Distância). Uma busca local que têm o potencial para ser usada em outros problemas parecidos com o PTD também foi criada, a BLBIR (Busca Local Baseada em Indivíduos Raros). Depois uma mescla das duas foi experimentada resultando em uma terceira busca local a BLMES (Busca Local Mesclada). A seção da BLMES, inclusive, apresenta uma estratégia para selecionar indivíduos na população, para aplicar a busca local, quando a população assume um Pareto único. O cerne dessa proposta foi a investigação da vizinhança de soluções sobre o funcionamento dessas três buscas locais, e com a seleção de indivíduos na população de forma reduzida para aplicação da busca local. Dessa forma, para cada uma das buscas locais, poucas soluções foram selecionadas na população para sofrerem alterações pela busca local e a vizinhança das soluções foram exploradas de maneira diferente apontando assim, uma regra do *pivot* mais adequada para este estudo. A nova abordagem pode ser sintetizada na Figura 10.

A proposta deste trabalho apresenta o mesmo *framework* de tratamento do PTD apresentado em ([NASCIMENTO, 2017](#)). Todavia, as principais mudanças ocorrem nos passos 5, 6 e 7 da Figura 10. Os passos de 1 a 4 e de 8 a 10 são os mesmos de

Fonte: o autor.

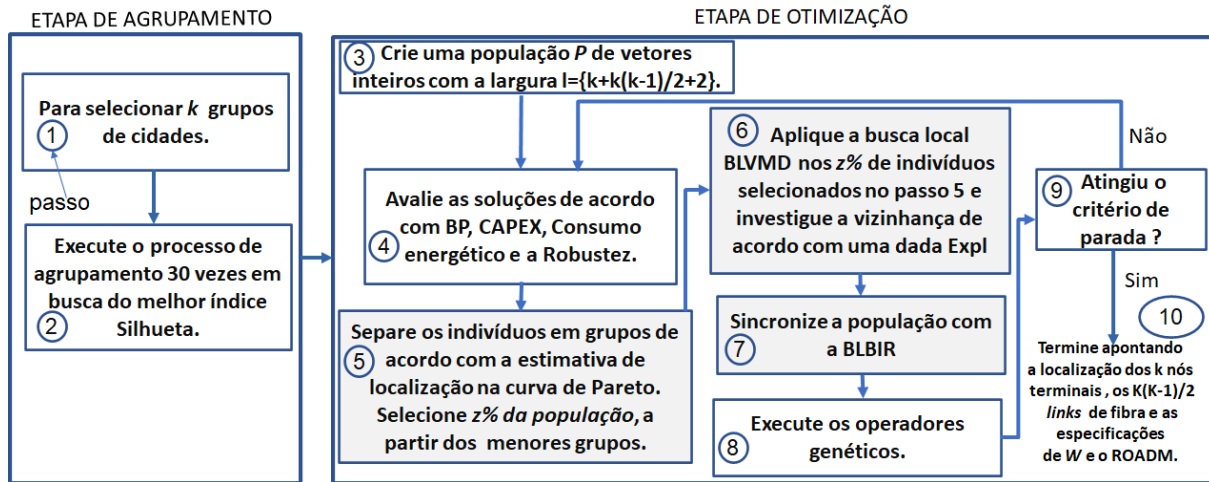


Figura 10 – Esquema geral da proposta.

(NASCIMENTO, 2017), porém, aqui a busca local não é aplicada a todos os membros da população desde o início da execução do algoritmo. E o motivo disso é que essa abordagem dobra o custo computacional da execução. E dobra o custo computacional em um problema que por si só já é custoso, o PTD.

Os passos 1 e 2 representam, respectivamente a seleção da quantidade de nós terminais da rede de transporte, quantidade essa que é um parâmetro de entrada, e a etapa de agrupamento realizada pelo algoritmo *Kmeans*. A etapa de agrupamento tem duas finalidades importantes. A primeira finalidade é separar o mapa da região, a qual a topologia de rede irá atender, em grupos de cidades bem definidos. A segunda finalidade é entregar para a etapa de otimização a localização geográfica das cidades centróides de cada grupo de cidade para que sirvam como nós terminais, iniciais, da rede de transporte, a etapa de agrupamento é especificada em (NASCIMENTO, 2017; NASCIMENTO et al., 2018). Os passos 3, 4, 8 e 9 são os passos normais de um EA, sendo que, o passo 8 acumula os operadores genéticos de seleção dos pais, mutação, cruzamento e seleção dos sobreviventes (EIBEN et al., 2003; LINDEN, 2008). Esses operadores genéticos também são os originais do NSGA-III implementado no Jmetal e não foram alterados (NEBRO et al., 2015). O passo 9 é o critério de parada. Os passos 5 a 8, porém, requerem mais atenção pois são os pontos chave dessa pesquisa.

O passo 5 só ocorre quando a população assume um Pareto único e contanto que não esteja sincronizada, o conceito de sincronização será explicado na Subseção 4.6.1. O Algoritmo 9, seleciona $z\%$ de soluções na população, de acordo com uma estimativa

de localização na curva de Pareto. Há dois objetivos em selecionar $z\%$ da população, o primeiro objetivo é chamado de objetivo de melhoramento da convergência, e, é que esses $z\%$ da população passem por procedimentos de melhoria através da busca local BLVMD, especificada na Seção 4.5. A melhoria da solução é através da descoberta da vizinhança da solução realizada pela busca local utilizando três tipos de exploração da vizinhança listados a seguir.

- **Expl1:** Sorteia um vizinho, entre os vizinhos mais próximos, no qual aplica a busca local, caso a nova solução domine a original, retorna a nova solução (NASCIMENTO et al., 2018).
- **Expl2:** Percorre todos os vizinhos mais próximos, e, aplica a busca local em cada um até encontrar um que domine a solução original, se encontrar, retorna a nova solução dominante e encerra a exploração, mesmo que ainda exista vizinhos pra explorar.
- **Expl3:** Percorre todos os vizinhos mais próximos, e, aplica a busca local em cada um, e, mesmo que encontre uma solução que domine original, não encerra a exploração. Substitui a solução original pela nova solução dominadora, e, continua a exploração da vizinhança na intenção de encontrar uma outra solução dominadora da dominadora. E faz isso até que não reste mais nenhum vizinho, mais próximo, para explorar. Por fim retorna o dominador do dominador, se encontrar.

A Expl1 é exatamente a mesma exploração da vizinhança usada em (NASCIMENTO et al., 2018). O objetivo de melhoramento da convergência está representado na Figura 10 no passo 6. O segundo objetivo é chamado de objetivo de sincronização e, é que esses $z\%$ de soluções selecionadas se juntem ao grupo que receberá o benefício de entrar na população dos pais através da busca local BLBIR que será explicada na Seção 4.6. O da sincronização está especificado na Figura 10 no passo 7. O mecanismo geral dessa abordagem é melhorar soluções que estão em localizações espaciais da curva de Pareto pouco ocupadas, e, multiplicar o número de soluções na área da curva de Pareto pouco ocupada, melhorando assim, a distribuição e a convergência da população. A maneira como a estimativa de áreas pouco ocupadas na curva de Pareto é feita, será detalhada na Seção 4.3.

4.2 O problema do Pareto único

Aplicar a busca local em toda a população não é uma opção interessante por causa do custo computacional que isso acarreta ([ABOUHAWWASH et al., 2017](#)), então é preciso selecionar uma quantidade de soluções menor que o tamanho da população para evitar invalidar a abordagem por causa do custo computacional, por isso é preciso estabelecer uma estratégia de seleção de indivíduos. Esta seção visa elucidar porque a questão da convergência pode não ser uma boa abordagem para selecionar soluções na população com a finalidade de aplicar uma busca local. Mas selecionar o indivíduo correto, dentre todos os indivíduos da população, não é uma tarefa simples.

Em um algoritmo evolucionário uma população de soluções baseada em dominância se divide em frentes de Pareto ([EIBEN et al., 2003](#)). A tarefa de escolher uma solução, em meio a população de soluções, facilmente leva a um raciocínio lógico de basear essa escolha em função das frentes de Pareto, mas para alguns problemas essa não é uma boa abordagem ([ABOUHAWWASH et al., 2017](#)). A Figura 11 mostra uma população de soluções de um problema de minimização com 14 soluções divididas em quatro frentes de Pareto. Do ponto de vista do Pareto populacional, uma abordagem onde o objetivo fosse selecionar poucos indivíduos para passar pela busca local, a regra do *pivot* referente a forma de selecionar soluções poderia ser, por exemplo, selecionar só os indivíduos mais convergidos para potencializar a convergência, Frente $F1$, ou, selecionar os menos convergidos para melhorar a população, Frente $F4$. No entanto, em problemas com mais de 2 objetivos, a população costuma assumir, rapidamente, um Pareto único onde nenhuma solução é melhor ou pior que a outra e sim equivalente, ou seja, é muito difícil estimar qual a mais apta para a seleção ([ABOUHAWWASH et al., 2017](#); [ZHOU](#); [WANG, 2014](#)).

Nos experimentos dessa pesquisa que trata de um problema com múltiplos objetivos, por exemplo, o algoritmo executou quinhentas iterações, porém, foi observado que a população assumia Pareto único frequentemente, entre nove e quinze iterações. Então, a seleção de poucas soluções para aplicação de uma busca local, baseado em convergência, não é uma abordagem funcional em problemas de múltiplos objetivos, portanto, nesta pesquisa a seleção de soluções foi baseada na distribuição da população e não na convergência. Dessa forma, para mitigar a questão do custo computacional associado ao incremento de novas avaliações de aptidão causados pela busca local, a quantidade de indivíduos selecionados por iteração foi limitada a um parâmetro de entrada, ou $z\%$, que não pôde

Fonte: (ARAÚJO, 2015)




Figura 11 – População de um EA baseada em dominância, distribuição em frentes de Pareto.

passar de 1,75% do total de indivíduos da população, o que se traduziu em no máximo 8 indivíduos por iteração de uma população de 456 indivíduos e esses 8 indivíduos foram selecionados em função do espalhamento.

4.3 Indivíduo raro

Esse conceito foi desenvolvido neste trabalho observando o funcionamento do hiperplano normatizado no ciclo do NSGA-III (DEB; JAIN, 2013) implementado no *framework* Jmetal (NEBRO et al., 2015). É um conceito que aborda a interdimensionalidade espacial dos elementos da população quando aplicados a um hiperplano normatizado de M dimensões onde M é o número de objetivos do problema. A intenção desse conceito é estimar uma área espacial na curva de Pareto que esteja pouco ocupada e trabalhar no aumento da ocupação desta área. Os exemplos serão dados em problemas de maximização e apesar de essa pesquisa ter tratado um problema com quatro objetivos, todos os exemplos citados nessa seção serão ilustrados para um problema de três objetivos por causa da natureza humana de visualizar apenas três dimensões espaciais (LOOS, 2019).

O hiperplano normatizado e a maneira como ele preserva a distribuição da população foi discutida na Subseção 3.3.3, a Figura 12A mostra um hiperplano normatizado. Na

Figura 12A os cruzamentos de retas marcam os pontos de referência que são equidistantes entre si, as soluções mais distribuídas que na Figura 12A são as esferas, são as soluções que mais se aproximam dos pontos de referência. Tomando cada eixo de função objetivo f_1 , f_2 e f_3 como uma dimensão, da Figura 12A para a Figura 12B os espaços entre dimensões do hiperplano foram setorizados totalizando a quantidade mínima de 3 objetivos arranjados 3 a 3, ou seja, seis setores: do *setor a* ao *setor f*.

Fonte: adaptado de (DEB; JAIN, 2013)




Figura 12 – Hiperplano normalizado sendo setorizado em um mínimo de M objetivos arranjados M a M , para 3 objetivos 6 setores, simbolizando possíveis localizações espaciais na curva de Pareto única.

A Figura 12B mostra que cada cruzamento de reta, ou ponto de referência, fica em um dos setores do hiperplano, uma forma de estimar, em termos práticos, em que setor está um ponto de referência é observando os seus valores dos eixos de função f_1 , f_2 e f_3 . Por exemplo, na Figura 12B se um ponto de referência tem a função f_3 como a função de maior valor entre as 3 funções que o localiza, esse ponto de referência vai estar em algum lugar com elevada amplitude no eixo da função f_3 , ou seja, no *setor a* ou *setor b*.

A Figura 12C mostra a setorização de forma mais clara para uma melhor apreciação, ainda é possível estimar se a solução está no *setor a* ou no *setor b* observando o valor de eixo de função que está como segundo maior valor, ou seja, se $f_3 > f_2 > f_1$, significa que f_2 é o segundo maior valor e o ponto de referência vai estar no *setor a*, todavia se

$f3 > f1 > f2$, então $f1$ é que será o segundo maior valor e o ponto de referência vai está no *setor b*. Como no hiperplano normatizado uma solução está próxima ao ponto de referência ao qual é associada, o raciocínio para estimar a localização de uma solução em termos práticos é o mesmo.

Entretanto, ainda há um certo custo computacional ao se separar a população de soluções em setores de acordo com a estimativa de localização no hiperplano porque se o número de objetivos do problema aumentar, as possibilidades de localização aumentam muito já que o número de setores é dado pelo número de eixos, ou seja, sendo x o número de eixos o número de setores será um arranjo simples de x eixos arranjados x a x . Por exemplo, se for aumentado o número de eixos de 3 para 4 a setorização sobe de 6 para 24, para 5 eixos já são 120 setores e assim por diante. A forma encontrada nesta pesquisa para fazer um relaxamento neste aspecto de quantidade de setores foi agrupando os setores em grupos de localizações espaciais.

Tomando como exemplo um PTD de três objetivos, CAPEX, PB e CA, cuja setorização do hiperplano pode ser mostrada na Figura 12B e associando o objetivo do CAPEX ao eixo de função $f3$, pode-se considerar as soluções que estão nos setores a e b como sendo soluções do grupo do CAPEX, pois estas soluções têm o valor da função CAPEX maior do que os valores da função PB e da função CA. Algo similar pode ser feita com as soluções dos setores c e e sendo consideradas como soluções do grupo do PB, analogamente as soluções dos setores d e f são consideradas como soluções do grupo do CA. Dessa forma, para cada objetivo um grupo, para 3 objetivos apenas 3 grupos, a Figura 13 ilustra o agrupamento, da Figura 13A para a Figura 13B os setores do hiperplano estão sendo agrupados.

Fonte: adaptado de (DEB; JAIN, 2013)




Figura 13 – Setores do hiperplano normatizado sendo agrupados em M onde M é o número de objetivos.

Uma população bem distribuída possibilita que o hiperplano normatizado retorne

uma distribuição com um número equilibrado de soluções em cada grupo onde a situação ideal seria que cada ponto de referência tivesse uma única solução localizada exatamente em sua posição, ou seja, soluções completamente equidistantes (DEB; JAIN, 2013). Neste trabalho, um hiperplano contendo grupos com o número de soluções muito abaixo da média foi tido como uma situação indesejada. A média da população foi tomada como sendo o número de soluções dividido pelo número de objetivos do problema, se no momento que a população assumir um Pareto único algum grupo ficar com o número de soluções muito abaixo da média, então, a população será considerada dessincronizada e o grupo com poucas soluções conterá soluções de uma localização na curva de Pareto única estimada como pouco ocupada.

Definição 1: Em um hiperplano normatizado, de M dimensões, que representa o espalhamento de uma população formada por um problema de M objetivos, se for feita uma setorização dos espaços internos do hiperplano, os indivíduos estarão espalhados em setores que tem o seu número definido por, no mínimo, um arranjo simples de M objetivos arranjados M a M . Um indivíduo raro, nesta pesquisa, é classificado como sendo uma solução que habita setores espaciais pouco ocupados.

E é muito importante destacar que é no mínimo um arranjo simples, com ênfase na palavra mínimo, pois, a depender da diferença de valores entre os objetivos o posicionamento assume vários inter espaços diferentes, entretanto, relaxamentos podem ser propostos para evitar custo computacional.

Então pela Definição 1 e pelo seu relaxamento, existem duas formas de observar a área interespaial de uma solução.

1. De forma detalhada: como na Definição 1, observando a sua localização em um nível mais profundo, ou seja, considerando um número de possíveis localizações igual a M objetivos arranjados M a M . Nesse caso o refinamento é mais preciso, mas vai exigir mais processamento.
2. De forma simples: observando só a sua grande área, seu classificador, ou seja, o melhor atributo de objetivo. Neste caso todas as soluções que são mais aptas no atributo x são classificadas como soluções do grupo x .

Nesse trabalho foi usado a forma simples, agrupando as soluções pelo seu melhor atributo, ou seja, para 4 objetivos (CAPEX, PB, Consumo energético e CA), são formados 4 grupos de localização espacial. Trabalhos futuros podem investigar a forma detalhada.

4.4 Melhorando a distribuição através do conceito de indivíduo raro

Durante os experimentos dessa pesquisa, observando o comportamento da população em termos de grupos, percebeu-se que na inicialização da população de forma aleatória no início da execução do EA, o grupo do CA muitas vezes aparecia com poucas soluções ou até vazio e essa condição se mantinha pela execução inteira.

Fonte: o autor




Figura 14 – Hiperplano normatizado com uma distribuição precária das soluções.

Quando acontecia do grupo do CA vir com poucas soluções, como na Figura 14, para aumentar a quantidade de soluções no grupo do CA, quando a população assumia um Pareto único, basta-se colocar na lista dos pais as soluções do grupo do CA aos pares para que passassem por procedimento de *crossover* e gerassem filhos parecidos com eles, portanto, capacitados a popular a localização estimada como pouco ocupada na curva de Pareto. Outra forma era colocar indivíduos do grupo do CA aos pares com indivíduos de outros grupos que tivessem o CA como segundo objetivo de melhor valor.

Já para os momentos em que o grupo do CA vinha vazio, colocava-se na lista dos pais soluções aos pares que eram de outros grupos, mas que tivessem o CA como segundo objetivo de melhor valor. Adotando-se esse procedimento, foi observado que após algumas iterações começavam a aparecer soluções no grupo do CA. Vale a pena lembrar que nesta pesquisa, o PTD foi tratado com quatro objetivos e como um problema de minimização, portanto, eram quatro grupos de soluções, um grupo para cada objetivo e o

que se procurava como melhor valor não era o maior valor de função e sim o menor.

As estratégias de aumento de quantidade de soluções em grupos estimados como pouco ocupados traduz a estratégia de melhorar a quantidade de soluções consideradas como indivíduos raros e deve ser aplicada iteração após interação em qualquer grupo que se mostre como grupo de poucas soluções e por isso grupo de indivíduos raros.

Na prática, se fez duas listas de listas, uma lista de listas batizada de $l1$ que separava a população pelo objetivo normalizado mais convergido, por exemplo, se uma solução tem o CAPEX como objetivo mais convergido significa que em termos de valores normalizados $CAPEX < (PB \vee CA \vee Consumo\ energético)$. Em $l1$ cada uma das quatro listas internas continha um grupo de soluções: uma lista para soluções mais convergidas em CAPEX, uma lista para soluções mais convergidas em PB e assim por diante. A segunda lista de listas foi batizada de $l2$ e separava a população pelo segundo objetivo normalizado mais convergido, por exemplo, uma solução que tem os valores normalizados de seus objetivos da seguinte forma $CAPEX < CA < PB < Consumo\ energético$, essa mesma solução entra em $l1$ na lista de CAPEX e em $l2$ na lista de CA, pois o CA é o segundo objetivo mais convergido. As estratégias de aumento de quantidade de soluções em um grupo considerado como grupo de indivíduos raros apresentadas nesta seção serão usadas na Seção 4.6 na busca local BLBIR.

4.5 BLVMD - Busca Local em Vizinhos por Menor Distância

Como dito, a busca local aplica conhecimento específico do problema ao EA. A busca local para o PTD, proposta neste trabalho, doravante chamada de BLVMD (Busca Local em Vizinhos por Menor Distância), é baseada na busca local publicada em (NASCIMENTO, 2017) e aplica conhecimento específico do PTD. O conceito desta busca local é focado em questões técnicas como explicado a seguir. O custo de implantação de uma topologia de rede óptica vem em parte do custo com a compra e com a implantação das fibras ópticas. O gasto com energia está associado a potência dos *lasers*, dos comutadores e de outros equipamentos envolvidos. Tais equipamentos têm diferentes consumos e eficiências energéticas, perante diferentes tipos e tamanhos de enlaces. A probabilidade de bloqueio é afetada por diversos fatores, dentre eles, as penalidades da camada física. Tais penalidades são alterados, entre outras questões técnicas, pelo tamanho do enlace. A

conectividade algébrica é alterada conforme altera-se a quantidade de enlaces envolvidos. O deslocamento da posição dos nós terminais interferem diretamente no comprimento dos enlaces, podendo trazer economia tanto com a quantidade de fibras usadas no enlace quanto na potência dos equipamentos eletrônicos envolvidos, como na potência dos *lasers* e ganho nos amplificadores, por exemplo. Dependendo da economia, o acréscimo de outro enlace pode melhorar a conectividade algébrica sem prejuízos ao custo final do projeto (TRONCO; AVILA, 2007; RAMASWAMI et al., 2009; ARAÚJO, 2015; DUPLEIX et al., 2016; NASCIMENTO et al., 2018; NASCIMENTO et al., 2020). A BLVMD parte do mesmo pressuposto da busca local apresentada em (NASCIMENTO et al., 2018), que a localização dos nós terminais é uma decisão tão complexa que também pode fazer parte do processo de otimização.

Basicamente, a BLVMD pega um projeto de topologia de rede devidamente avaliado, escolhe um dos nós terminais através de sorteio. Então, troca o nó terminal, entre cidades vizinhas, de acordo com uma dada configuração de regra do *pivot*. Como o nó terminal está instalado em uma cidade e a BLVMD procura deslocar o nó terminal para uma das cidades vizinhas, as quais, são classificadas como vizinhas por estar entre as cidades de menor distância, é literalmente uma busca local em vizinhos por menor distância física. Depois a BLVMD insere um enlace novo entre dois nós quaisquer da rede. Mais uma vez esses dois nós terminais da rede que recebem um enlace novo são sorteados e nenhum deles é necessariamente o nó que foi trocado de cidade. Vale ressaltar que a inclusão desse enlace é justamente o que difere a BLVMD, aqui proposta, da busca apresentada em (NASCIMENTO et al., 2018). Dessa forma, a BLVMD descobre uma solução vizinha à solução original. Por fim a BLVMD avalia a solução vizinha descoberta e se a solução vizinha dominar a solução original a BLVMD substitui a solução original pela vizinha na população. Dado os nós terminais iniciais da rede pela etapa de agrupamento (NASCIMENTO, 2017), os nós terminais continuam sendo alterados na seguinte ordem:

1. Sorteia um dos k grupos de cidades.
2. Aplica a busca local, explorando a vizinhança, de acordo com a regra do *pivot* e suas configurações.
3. Sempre que encontrar um novo vizinho o avale.
4. Se a solução vizinha dominar a atual, a busca local substitui ela na população.

Os Algoritmos 4, 5, 6, 7, compõe a apresentação do pseudocódigo da busca local

BLVMD. O algoritmo 4, mostra o algoritmo principal da BLVMD, a partir dele são chamados os algoritmos 5, 6, 7.

Algoritmo 4: Busca Local Baseada em Vizinho de Menor Distancia-BLVMD

Entrada: 1 - Lista de grupo de cidades Lgc
Entrada: 2 - Lista de cidades POPs Lp
Entrada: 3 - Número K de vizinhos mais próximos
Entrada: 4 - Uma forma de exploração **Expl**
Entrada: 5 - Lista das soluções que foram selecionadas para a busca local Ls

```

1 for cada  $s$  in  $Ls$  do
2    $i = \text{sorteio de } 1 \text{ a } Lp_{\text{tamanho}} ;$  // sorteia um grupo de cidades
3    $grupo = Lgc[i] ;$  // seleciona o grupo sorteado
4    $POP = Lp[i] ;$  // seleciona a cidade POP
   /*  $Lv$  recebe a lista de vizinhos mais próximos */
5    $Lv = \text{VizinhoMaisProximo}(grupo, POP, K);$ 
   /* explore a vizinhança de acordo com uma dada exploração Expl */
6   if  $Expl == 1$  then
7      $s = Expl1(POP, Lv, Lp, s);$ 
8   end
9   if  $Expl == 2$  then
10     $s = Expl2(POP, Lv, Lp, s);$ 
11  end
12  if  $Expl == 3$  then
13     $s = Expl3(POP, Lv, Lp, s);$ 
14  end
15  substitua  $s$  na população;
16 end

```

A entrada do Algoritmo 4 é a lista dos grupos de cidades Lgc , a lista de cidades POPs, o número K de vizinhos mais próximos, uma forma de exploração da vizinhança $Expl$, e, a lista de soluções que passará pelo procedimento de busca local. A lista dos grupos de cidades, Lgc , é a lista de grupos de cidades feita pela etapa de agrupamento, onde cada cidade da região para a qual a topologia está sendo projetada foi associada a um grupo. A lista de cidades POPs é a lista de quais cidades foram designadas para portar o nó terminal da rede de transporte. Cada grupo de cidade tem uma cidade que contém um POP, e, na implementação desse projeto, a primeira posição da lista de cidades POPs Lp é a cidade POP que pertence ao primeiro grupo de cidade de lista de grupos de cidades Lgc . O número K de vizinhos mais próximos é o número de vizinhos que o algoritmo deve considerar como vizinhos mais próximos. A forma de exploração $Expl$ da vizinhança é a forma como a busca local vai averiguar a vizinhança que está definido neste

capítulo como *Expl1*, *Expl2* e *Expl3*. A lista de soluções que foram selecionadas para a busca local *Ls* é a lista de soluções que irão passar pelo procedimento de busca local.

Na linha 1 o *loop for* itera sobre as soluções da lista de soluções *Ls*. Na linha 2, um grupo de cidades entre os n grupos de cidades é sorteado. Na linha 3, o grupo de cidades sorteado é recuperado. Na linha 4, a cidade POP desse grupo é recuperada. Na linha 5 a lista de cidades vizinhas, para a solução da iteração do *loop*, é recuperada a partir do Algoritmo 5. Da linha 6 a linha 14, o algoritmo explora a vizinhança de acordo com um dado esquema de exploração, a partir do uso dos Algoritmos 6, 7. Na linha 15 a solução s é substituída na população, se o algoritmo encontrou solução dominante s é uma solução nova.

Algoritmo 5: VizinhosMaisProximos (Auxiliar 1- BLVMD)

Entrada: 1 - Grupo de cidades *grupo*
Entrada: 2 - Cidade com o nó terminal *POP*
Entrada: 3 - Número K de vizinhos mais próximos

```

1 grupo = grupo - POP ;                               // remove a cidade POP do grupo
2  $Tg = grupo_{tamanho}$  ;                               // Tg recebe tamanho do grupo de cidades
3 for  $x$  de 1 a  $Tg$  do
4   cidade = grupo[ $x$ ];
5   if distância do POP até cidade == menor distância then
6     |  $Lv = cidade$  ;                               // Lista de vizinhos Lv recebe vizinho mais próximo
7   end
8    $T = Lv_{tamanho}$ ;
9   if  $T == K$  then
10    | pare;
11  end
12  grupo = grupo - cidade ;                             // remove a cidade selecionado do grupo
13 end
14 return  $Lv$ ;

```

O algoritmo 5, recupera a lista de cidades vizinhas a partir da cidade que detém o POP. A entrada do Algoritmo 5 é o grupo de cidade *grupo*, a cidade que detém o nó terminal da rede de transporte *POP* e o número de vizinhos a ser considerado.

Na linha 1, a cidade que tem o POP é removida do grupo para que o algoritmo não a considere ao medir as distâncias entre as cidades. É importante observar que no início da execução do Algoritmo NSGA-III uma matriz de distâncias entre as cidades é calculada e mantida, o que reduz o cálculo da distância entre cidade a uma consulta a matriz pelo resto da execução. Na linha 2, uma variável com o tamanho do grupo é

instanciada para limitar a execução do *loop* da linha 3. Na 3 inicia-se o *loop* que calcula os K vizinhos mais próximos. Da linha 3 até a linha 13 uma lista, L_v , é preenchida com os K vizinhos mais próximos. Na lista L_v o vizinho de menor distância entra na cabeça da lista e o vizinho com a segunda menor distância entra na segunda posição da lista e assim sucessivamente, ou seja, a lista L_v é ordenada do mais próximo até o mais distante. Na linha 9 a condicional garante que a lista terá exatamente o tamanho de K vizinhos. Na linha 14 a lista L_v é retornada.

Já o Algoritmo 6, realiza a exploração da vizinha *Expl1*, vale ressaltar que essa exploração da vizinhança é a exploração praticada em (NASCIMENTO et al., 2018).

Algoritmo 6: Expl1 (Auxiliar 2- BLVMD)

Entrada: 1 - Cidade com o nó terminal *POP*
Entrada: 2 -Lista de cidades vizinhas mais próximas L_v
Entrada: 3 - Lista de cidades POPs L_p
Entrada: 4 - Solução s

```

1  $Sc = s$  ; // Sc recebe uma cópia da solução s
2  $K = L_{v_{tamanho}}$  ; // K recebe o tamanho da lista de cidade vizinhas
3 índice = sorteio de 1 a K;
4  $C_v = L_v[\text{índice}]$  ; // C_v recebe cidade vizinha sorteada
/* Na cópia da solução transfere o POP para cidade vizinha */
5  $Sc = Sc$  com POP transferido para  $C_v$  ;
6  $Tam = L_{p_{tamanho}}$  ; // T recebe tamanho da lista de POPs
7  $Te = true$  ; // variável Te (tem enlace) recebe true
8 while  $Te$  do
9    $i = \text{sorteio de } 1 \text{ a } Tam$  ; // i recebe o sorteio da posição de um dos POPs
10   $j = \text{sorteio de } 1 \text{ a } Tam$  ; // j recebe o sorteio da posição de outro dos POPs
/* se não houver enlace entre os POPs saia do loop */
11  if  $Sc[i,j] = 0$  then
12     $Te = false$ 
13  end
14 end
15  $Sc[i,j] = 1$  ; // a topologia recebe um enlace a mais em [i,j]
/* Se a cópia Sc dominar a solução s */
16 if  $Sc$  domina  $s$  then
17    $s = Sc$  ; // solução original s recebe a cópia modificada
18 end
19 return  $s$  ;
```

No algoritmo 6, com as entradas sendo a cidade com o nó terminal *POP* (apenas para o algoritmo saber onde o POP está quando for transferi-lo), a lista de cidades vizinhas L_v , a lista de cidades POPs L_p e a solução s , o algoritmo começa a exploração da

vizinhança. Na linha 1 a solução s é copiada para a variável Sc . Na linha 2 uma variável K é criada para o tamanho da lista de Lv . Na linha 3, uma posição da lista de cidades vizinhas Lv é sorteada. Na linha 4 a cidade vizinha sorteada na linha 3 é recuperada para a variável Cv . Na linha 5, o nó terminal da rede de transporte é transferido da cidade POP para a cidade Cv sorteada. Da linha 6 a linha 15 um par de cidades escolhidas aleatoriamente recebem um enlace novo entre as duas. Na linha 16, a condicional verifica se a cópia Sc , modificada, da solução s , domina a solução s . Se dominar a solução s é sobrescrita, linha 17. Na linha 19 o algoritmo retorna a solução s .

Já o Algoritmo 7, realiza a exploração da vizinhança $Expl2$, e também pode ser usado para ilustrar a $Expl3$ já que a única diferença do procedimento da $Expl2$ para $Expl3$ é que no procedimento da $Expl3$, não existe a solicitação de parada da linha 16 do Algoritmo 7, $Expl2$, o que força a $Expl3$ a investigar a vizinhança inteira.

Algoritmo 7: Expl2 (Auxiliar 3- BLVMD)

Entrada: 1 - Cidade com o nó terminal POP
Entrada: 2 -Lista de cidades vizinhas mais próximas Lv
Entrada: 3 - Lista de cidades POPs Lp
Entrada: 4 - Solução s

```

1   $Tam = Lp_{tamanho}$  ;                               // T recebe tamanho da lista de POPs
2  for cidade vizinha  $Cv$  em  $Lv$  do
3       $Sc = s$  ;                                         // Sc recebe uma cópia da solução s
      /* Na cópia da solução transfere o POP para cidade vizinha */
4       $Sc = Sc$  com POP transferido para  $Cv$  ;
5       $Te = true$  ;                                     // variável Te (tem enlace) recebe true
6      while  $Te$  do
7           $i = \text{sorteio de } 1 \text{ a } Tam$  ; // i recebe o sorteio da posição de um dos POPs
8           $j = \text{sorteio de } 1 \text{ a } Tam$  ; // j recebe o sorteio da posição de outro dos
              POPs
          /* se não houver enlace entre os POPs saia do loop */
9          if  $Sc[i,j] == 0$  then
10              $Te = false$ 
11         end
12     end
13      $Sc[i,j] = 1$  ;                                   // a topologia recebe um enlace a mais em [i,j]
      /* Se a cópia S dominar a solução original s */
14     if  $Sc$  domina  $s$  then
15          $s = Sc$  ;                                     // solução original s recebe a cópia modificada
16         pare;
17     end
18 end
19 return  $s$ ;

```

No Algoritmo 7, as entradas são as mesmas do Algoritmo 6. Na linha 1, uma variável Tam é instanciada para o tamanho da lista de Cidades nós terminais $POPs$. Na linha 2 começa o *loop* que irá explorar a vizinhança da solução s . Na linha 3 a solução s é copiada para a variável Sc . Na linha 4, o nó terminal é transferido para a cidade vizinha Cv . Da linha 5 a linha 13 um par de cidades escolhidas aleatoriamente recebe um enlace novo entre as duas. Na linha 14, a condicional testa se a cópia modificada Sc domina a solução original s , caso domine, na linha 15, s é sobrescrita por Sc . Na Linha 16 há uma instrução de parada do *loop* que inicia na linha 2. Isso significa que se uma solução dominante for encontrada, a execução para e a solução dominante é retornada. O passa 16 é justamente o que difere a *Expl2* da *Expl3*. Na *Expl3*, a instrução de parada não existe o que faz o algoritmo examinar a vizinhança inteira.

Todavia, para se entender qualquer busca local de forma mais concisa é necessário primeiro se entender o conceito específico de vizinhança adotado para a busca local. Cada cidade que possui um nó terminal da rede de transporte é cercada por um número x de cidades que são classificadas como cidades mais próximas, onde x é um parâmetro de entrada. Uma solução vizinha neste estudo, para a busca local BLVMD é um projeto de topologia de rede com um dos nós terminais da rede de transporte deslocado para uma das cidades vizinhas a este nó e com um enlace a mais entre dois nós quaisquer escolhidos por sorteio.

4.5.1 Exemplo de busca local BLVMD

A Figura 15 mostra o esquema da busca local, BLVMD, onde o Grupo de cidades 4 foi selecionado pelo algoritmo para a aplicação da busca local. O nó terminal mudou da cidade $C1$ para a cidade $C2$, e o Enlace 5 foi adicionado encontrando uma solução vizinha. Se a solução vizinha dominar a original as soluções são substituídas na população.

Fonte: adaptado de (NASCIMENTO et al., 2020)




Figura 15 – Exemplo de atuação da busca local em vizinho de menor distância BLVMD.

4.6 Busca Local Baseada em Indivíduos Raros - BLBIR

Uma busca local tem a função de aplicar conhecimentos específicos de um problema ao EA. Então, falar em uma busca local que se proponha a ser aplicada em vários problemas parece algo que não faz muito sentido. Todavia, foi destacado na Subseção 3.3.3 que problemas com mais de dois objetivos, geralmente, tem dificuldades para manter a diversidade da população. Então, de uma forma abstraída, é possível adotar o ponto de vista de que espalhamento da população é uma questão específica para vários problemas combinatórios de múltiplos objetivos (*Many objective*). Contudo, existem vários estudos que o tratam o problema da diversidade da população, em problemas de múltiplos objetivos, através de outros operadores evolucionários como o operador de seleção dos sobreviventes (DEB; JAIN, 2013; DAS; DENNIS, 1998; ZHANG; LI, 2007). Entretanto, no levantamento bibliográfico feito para essa pesquisa, não foi encontrado nenhum registro de trabalho que lidasse com o problema do espalhamento da população como uma questão a ser auxiliada por uma busca local, e, observando o compromisso entre qualidade de soluções e custo computacional.

A segunda proposta de busca local desta pesquisa procura fornecer uma abordagem de busca local que auxilie o espalhamento da população e que possa ser aplicada a um número maior de problemas combinatórios, mantendo bom compromisso entre qualidade das soluções e custo computacional. Com isso houve dois desafios:

- 1°. Desafio: propor a busca local com potencial para ser aplicada para mais de um problema combinatório.
- 2°. Desafio: equilibrar o custo computacional extra da busca local de modo que os benefícios em termos de qualidade das soluções superem o efeito de custo computacional. Em outras palavras, é desejável obter soluções de melhor qualidade quando um tempo máximo for especificado para diferentes abordagens.

Como explica a Subseção 3.3.4, uma busca local insere no problema um custo computacional extra ao necessitar de reavaliação da solução. Em (ZHOU; WANG, 2014), porém, uma abordagem diferente foi usada. Invés de usar os operadores genéticos, avaliar a solução e depois aplicar a busca local, o trabalho usou a própria busca local como operador genético eliminando uma das avaliações de aptidão do processo. Então, o segundo desafio, específico para a BLBIR foi organizar a busca de forma a aproveitar a avaliação normal do processo.

4.6.1 Mecanismo da BLBIR

Como destacado na Seção 4.4, os mecanismos de um EA podem ter dificuldades de oferecer ao operador de sobreviventes uma variedade de soluções suficientes para prover uma seleção de população bem distribuída. A BLBIR materializa a estratégia de melhoramento de distribuição explicada na Seção 4.4, usando as listas de listas $l1$ e $l2$ também definidas na Seção 4.4 e com base na *Definição 1* em sua forma relaxada discutida na Seção 4.3. Além disso a BLBIR também tem um mecanismo que, quando ativado, pega soluções melhoradas com sucesso por outras buscas locais na iteração corrente, e tenta exportar essas melhorias para gerações futuras através dos operadores genéticos, esse mecanismo será usado na Seção 4.7

Olhando a população como um grupo de elementos aptos a preencher setores do hiperplano discutidos na seção 4.3, a BLBIR tem por objetivo potencializar a chance dos operadores genéticos de multiplicarem ou gerarem soluções que consigam preencher lacunas vazias ou pouco habitadas do hiperplano normatizado como na Figura 14. A BLBIR é aplicada apenas quando o Pareto populacional é único, na Seção 4.3 foi dito que se no momento que a população assumir um Pareto único algum grupo ficar com o número de soluções muito abaixo da média que é um conceito definido na própria Seção 4.3, então, a população será considerada dessincronizada, dessa forma, é preciso definir o

que é ficar muito abaixo da média.

Nesta pesquisa foi montada uma lista nomeada como *sinc* e do tamanho de M , onde M é o número de objetivos, e cada posição de *sinc* continha um número decimal que representava a porcentagem de indivíduos na população que era mais convergido em um dos objetivos, a noção de maior convergência em um dos objetivos foi dado na Seção 4.4. Por exemplo, sendo o tamanho da população inteira considerado como 1, ou seja $100\% = 1$, e sendo o problema de 4 objetivos, *sinc* terá 4 posições onde cada posição tem que ter 0,25, ou seja $1/4 = 0,25$, para que a população seja considerada sincronizada. O que implica que no exemplo de uma população com 456 indivíduos e 4 objetivos, 0,25 da população seria 114 soluções e cada grupo teria 114 soluções, ou seja, a média da população $456/4 = 114$. Se a população está sincronizada, $sinc = \{0,25; 0,25; 0,25; 0,25\}$, há uma boa chance do operador de seleção dos pais retornar uma população satisfatoriamente distribuída, então, não há necessidade de uso da BLBIR.

Todavia, uma população sincronizada dessa forma não foi observada nos experimentos desta pesquisa, portanto de forma empírica foi adotado uma tolerância para o conceito de sincronização e uma variância populacional igual a 0,01 de *sinc* foi usada, estudos futuros podem experimentar novos valores de variância. Por exemplo, se os valores de *sinc* não forem todos iguais a 0,25 a população ainda será considerada sincronizada se a variância populacional de *sinc* não ultrapassar 0,01. Na prática, com uma população de 456 soluções e sendo os números decimais de *sinc* associados aos percentuais de grupos de soluções na seguinte ordem: $sinc[0] = PB$, $sinc[1] = CAPEX$, $sinc[2] = \text{Consumo energético}$, $sinc[3] = CA$, se todas as posições de *sinc* fossem iguais a 0,25 cada grupo de soluções teria 114 soluções, a variância seria igual a zero e a população estaria sincronizada. Porém, se *sinc* fosse por exemplo igual a $\{0,35; 0,15; 0,42; 0,08\}$, em números os grupos estariam quantificados com aproximadamente $\{160; 68; 192; 36\}$ indivíduos, a variância seria igual a 0,02593 e portanto maior que 0,01, a população seria considerada dessincronizada, os grupos de CAPEX com 68 e CA com 36 soluções seriam considerados grupos de indivíduos raros e essa situação seria um exemplo do que é está muito abaixo da média.

A BLBIR faz um pré preenchimento de uma fatia pequena da lista dos pais, antes da atuação do operador de seleção dos pais colocando soluções que foram melhoradas pela BLVMD além de executar as estratégias definidas na Seção 4.4. O Algoritmo 8 explica o

funcionamento da BLBIR, sendo $l1$ e $l2$ exatamente como definidas na Seção 4.4 e sendo $Lneed$ uma lista de listas onde cada lista interna, Lis , contém duas posições em que $Lis[0]$ contém o índice do grupo em $l1$ que foi classificado como raro, e, $Lis[1]$ contém o número que falta pra o grupo chegar a média. O Algoritmo 8 mostra a BLBIR fazendo uma espécie de reprodução controlada e exportando melhorias da BLVMD para gerações futuras que, quando as melhorias existem, ativam o mecanismo da BLVMD para exportar melhorias.

Algoritmo 8: Busca Local Baseada em Indivíduos Raro - BLBIR (Mating control)

```

1  ListaPais =MelhoradosPorBLVMD;
2  for each Lista Lis pertencente a Lneed do
3      limit = Lis[1];           // o limite é o número que falta pra chegar a média
4      for each solucao pertencente l1[Lis[0]] do
5          ListaPais = solucao;
6          if ListaPais >limit then
7              pare;
8          end
9      end
10     numeroDeCilos = Lis[1];
11     ciclos = 0;
12     while ListaPais <limit ou ciclos <numeroDeCilos do
13         l1[Lis[0]].embaralhe;
14         ListaPais = cabeça da lista l1[Lis[0]];
15         l2[Lis[0]].embaralhe ;           // 12 tem a mesma organização de 11
16         ListaPais = cabeça da lista l2[Lis[0]];
17         ciclos = ciclos + 1;
18     end
19 end

```

A linha 1, do Algoritmo 8, coloca na lista de pais todos os indivíduos melhorados pela BLVMD, quando houver, dessa forma os indivíduos melhorados pela busca local BLVMD, que nesta pesquisa atua em elementos classificados como indivíduos raros, são os primeiros a serem privilegiados na população dos pais. Da linha 2 até a 19 continua o preenchimento da lista dos pais. Na linha 3, uma variável, *limite* é instanciada com a posição 1 da lista *Lis*, essa posição contém o número de soluções que esse grupo de indivíduos raros precisa para alcançar a média. Da linha 4 a 9, a lista de pais é preenchida com os indivíduos do grupo raro de $l1$ indicados pela posição zero da lista *Lis*. Na linha 5, cada solução do grupo raro é colocada na lista dos pais. A lista dos pais sofre operação de cruzamento aos pares, portanto, se um indivíduo raro for colocado na posição zero da lista dos pais e outro indivíduo raro for colocado na posição um, esses indivíduos raros

serão os pais de dois filhos da próxima geração. Na linha 6, 7 e 8 há uma condição de parada limitando o tamanho da lista de pais ao número de indivíduos que faltam para que o grupo de indivíduos raros atinja a média. Da linha 10 até a linha 18 um *loop while* preenche a lista dos pais em duas situações. Na primeira situação existem indivíduos raros na lista de indivíduos raros e, neste caso, o Algoritmo 8 nas linhas 14 e 16, coloca na lista dos pais, indivíduos raros intercalados com indivíduos de $l2$ que têm o segundo objetivo mais convergido igual ao objetivo que classifica o grupo de indivíduos raros, dessa forma haverá um cruzamento entre uma espécie de indivíduo puramente raro com um indivíduo com traços de raro. Na segunda situação, não há indivíduos no grupo de indivíduos raros e, neste caso, o Algoritmo 8, nas linhas 15 e 16, coloca na lista dos pais, apenas os indivíduos de $l2$ que têm o segundo objetivo mais convergido igual ao objetivo que classifica o grupo de indivíduos raros, materializando assim, as estratégias explicadas na Seção 4.4. A hipótese é que a cada ciclo indivíduos com características mais próximas a dos indivíduos raros apareçam, até que, comecem a aparecer indivíduos puramente raros. Caso não haja nem indivíduos na lista de indivíduos raros e nem indivíduos de $l2$ que têm o segundo objetivo mais convergido igual ao objetivo que classifica o grupo de indivíduos raros o *loop while* da linha 12 a 18 não faz nada e para assim que atingir o número de ciclos igual a variável *numeroDeCilos* definida na linha 10. Todavia, neste estudo, nos procedimentos de *debug* realizados, o problema do PTD não apresentou situações em que a lista de listas de indivíduos $l2$ estivesse com alguma lista interna vazia.

Dessa forma a BLBIR procura soluções vizinhas sem alterar nenhum indivíduo na população, o que significa que ela não tem custo computacional relativo a uma nova avaliação de aptidão já que não altera indivíduos, pois para a BLBIR uma solução não é um indivíduo da população e sim a distribuição de uma população inteira. Mas nesse caso é preciso entender o que é uma solução vizinha para a BLBIR, tomando como uma solução a distribuição exemplificada na Figura 14, uma solução vizinha melhor seria qualquer distribuição onde a área pouco ocupada fosse um pouco mais populada. Por exemplo, na Figura 14 há 3 soluções no grupo do CA, se uma nova distribuição retornasse uma população com 4 soluções seria uma solução vizinha melhor e se retornasse com 2 seria uma solução vizinha pior.

4.7 Mescla da BLBIR com A BLVMD

Essa seção mostra a mescla da BLBIR e da BLVMD, doravante chamada de BLMES, ou seja, mostra como as duas buscas locais trabalham em sintonia. Esta seção também apresenta o algoritmo para uma questão importante para esse estudo, se não vai aplicar a busca local em todos os indivíduos da população, qual indivíduo escolher para aplicar a busca local quando a população assumir um Pareto único? Tendo como parâmetro de entrada uma porcentagem da população $z\%$ e sendo $l1$ exatamente como explicada na Seção 4.4, a partir do momento em que a população assume um Pareto único e contanto que a população não esteja sincronizada, a BLMES usa um procedimento de seleção de indivíduos, privilegiando indivíduos raros na população, para aplicar a BLVMD e depois tentar sincronizar a população com a BLBIR. O Algoritmo 9, mostra o procedimento de seleção de indivíduos, privilegiando os indivíduos raros, para aplicação da BLVMD.

Algoritmo 9: Seleção de indivíduos na população, com privilégio para os raros, para entregar a Mescla da BLBIR e a BLVMD, nomeada de BLMES.

```

1  $l1 = l1_{ordenada}$  ; // ordena l1 da lista menor para a maior
2  $ListaRetorno = listaVazia$ ;
3 for each Lista LI pertencente a l1 do
4   if  $ListaRetorno.tamanho == z\%$  da população then
5     Pare;
6   end
7   while  $LI.tamanho > 0$  do
8     LI.embaralhe;
9      $ListaRetorno = LI[0]$ ;
10     $LI[0].remove$ ;
11    if  $ListaRetorno.tamanho == z\%$  da população then
12      Pare
13    end
14  end
15 end
16 return  $ListaRetorno$ ;

```

Dessa forma a busca local é aplicada em indivíduos raros a cada ciclo, pegando membros do menor para o maior grupo e de forma aleatória dentro de cada grupo, essa seleção de indivíduos se limita a parar em $z\%$ da população, todavia o número de $z\%$ tem que ser pequeno para a abordagem fazer sentido, não seria o objetivo da abordagem, mas o parâmetro de entrada $z\%$ pode ser configurado como 100% da população e nesse caso os

indivíduos selecionados deixariam de ser os raros e passaram a ser todos. O que acontece é que a técnica foi desenvolvida para não impactar demais no custo computacional total do algoritmo com avaliações de aptidão extras causadas pela busca local. Portanto, apesar de ser possível a configuração de $z = 100\%$, não faz sentido que se configure, por exemplo, os $z\%$ da população traduzidos em números, nos experimentos deste trabalho, foram quatro e oito indivíduos em uma população de 456, o que gerou um impacto de menos de 2% no total de avaliações de aptidão a mais no custo total do algoritmo por causa das avaliações de *exploitation*. O que pode ser facilmente compensado em termos de *trade-off* com as avaliações de aptidão relativas a *exploration*.

Por exemplo, supondo uma população de 200 soluções para os quatro grupos dessa pesquisa, após cada solução ser separada em listas de acordo com seu grupo e inseridas em *l1*, as listas de listas em *l1* foram ordenadas de forma crescente pelo seu tamanho da seguinte forma:

- 1°. Conectividade algébrica: com apenas 4 membros.
- 2°. Consumo energético: com 40 membros.
- 3°. Probabilidade de bloqueio: com 76.
- 4°. CAPEX: com 80 membros.

O Algoritmo 9, então, tem a missão de selecionar $z\%$ desses 200 membros da população para aplicar a busca local BLVMD. Estando a população separada em grupos como na lista acima e os $z\%$ da população se traduzindo em 8 indivíduos, seriam selecionados os 4 indivíduos do grupo da conectividade algébrica e mais 4 do grupo do Consumo energético capturados aleatoriamente. Portanto, o Algoritmo 9 selecionará $z\%$ de soluções privilegiando os grupos considerados grupos de indivíduos raros e de forma aleatória conforme linhas 8 e 9 do Algoritmo 9.

Na linha 1, o Algoritmo 9 ordena a lista de grupos de soluções *l1* de forma que a lista interna à *l1* que fica na posição $i = 0$ seja a menor em número de membros, enquanto a $i - \text{esima}$ lista seja a maior. Na linha 2 é iniciada uma lista vazia que receberá o retorno do Algoritmo 9. O *loop for* iniciado na linha 3 e que vai até a linha 15, preenche a lista de retorno do Algoritmo 9 com a quantidade de soluções igual a $z\%$ da população. Mas o preenchimento da lista de retorno do algoritmo que acontece da linha 8 até a 14 é feito do menor para o maior grupo, dessa forma, privilegiando os indivíduos raros. O critério de parada para o *loop for* da linha 3 a 15 é que a lista de retorno atinja o tamanho de $z\%$

da população. Esse critério de parada é averiguado 2 vezes, primeiro nas linhas de 4 a 6 para que a partir da segunda iteração do *loop for* da linha 3 a 15, caso o limite tenha sido alcançado, o algoritmo pare. Depois dentro do *loop while*, nas linhas de 11 a 13, para que se o limite for alcançado dentro do *loop while* o algoritmo pare. Na linha 16 o Algoritmo 9 retorna uma lista com o tamanho de $z\%$ da população, preferencialmente, apenas com indivíduos considerados raros.

A estratégia por trás da BLMES é que a BLVMD irá melhorar soluções nas regiões onde a BLBIR irá atuar (região de indivíduos raros). Portanto, a estratégia da BLMES é a resposta desse trabalho a questão de em que solução aplicar a busca local quando a população entra em um Pareto único. Como no momento que a população entra em Pareto único não existe solução melhor que a outra, pois, todas elas são dominadas entre si, a estratégia de seleção de poucos indivíduos para aplicação de uma busca local passa a ser em função de melhorar indivíduos que farão parte de uma tentativa de sincronização da população. Essa tentativa de sincronização da população é uma estratégia para ampliar as chances do operador de seleção de sobreviventes em preencher lacunas na curva de Pareto, estimadas em termos práticos.

Lembrando que a BLVMD melhora uma solução em meio à população, enquanto a BLBIR procura a sincronização da população enviando indivíduos raros para a população dos pais para que tenham filhos parecidos com eles. Então, se as melhorias são feitas em indivíduos raros, com a ajuda dos operadores genéticos as chances de essas melhorias avançarem para a próxima geração junto com o grupo de indivíduos raros também aumentam. Resumidamente, como a aplicação das melhorias provenientes das investidas de sucesso da BLVMD tendem a ser poucas, pois a BLVMD é aplicada em poucos indivíduos a ideia é usar os operadores genéticos para aumentar as chances de exportar para as gerações futuras essas melhorias, através do cruzamento de soluções. A estratégia é totalmente estocástica, todavia, quando a técnica é usada por inteiro como explicado e batizado de BLMES, os resultados são promissores.

O Algoritmo 10 utiliza o NSGA-III como fluxo básico e aplica as propostas meméticas descritas neste capítulo. Portanto, o Algoritmo 10 sintetiza todas as propostas deste trabalho em um procedimento único.

Na Linha 1 do Algoritmo 10, um contador de tempo que identifica as gerações é iniciado. Na linha 2, uma população aleatória é inicializada. Na linha 3 a função de

Algoritmo 10: NSGA-III - HÍBRIDO

```

1  T:=0; ;                                     // Inicialize o contador de tempo da geração
2  Inicializa População P(0);                  // Inicialize aleatoriamente
3  Avalie População P(T);                      // Avalie a população atual.
4  while não atingir condição de término do
5      Pais = lista vazia;
        /* Os passos 7,8 e 9 estão condicionados à população P(T) não estar
           sincronizada e P(T) estiver em um Pareto único */
6      if  $P(T)$  não estiver sincronizada e o Pareto for único then
        /* selecione z% da população P(T), entre os indivíduos raros */
7          Algoritmo 9 - Seleção de indivíduos na população;
        /* Aplique o operador de otimização local em Vizinhos de Menor Distância
           */
8          BLVMD Algoritmo 4 - nos z% da população;
        /* Aplique o operador de otimização local Baseado em Indivíduos Raros */
9          Pais = BLBIR(P(T)) Algoritmo 8 - sincronização a partir dos indivíduos
            raros;
10     end
        /* Complete a lista dos pais - Seleção dos pais */
11     Pais= torneio binário ( P(T));
        /* Aplique os operadores genéticos */
12     Filhos=Recombinação de Pais;
13     Filhos= mutação;
14     Avalie População de Filhos;              // Avalie esta nova população
15     P(dobro) = P(T) + Filhos;
        /* Ordene P(dobro) em frentes de Pareto */
16     fast-non-dominated-sort (P(dobro)) - Algoritmo 1;
        /* Seleção de sobreviventes */
17     P(T+1) = Seleção dos sobreviventes - hiperplano normalizado (P(dobro)) ;
18     T:=T+1 ;                                // Incremente o contador de tempo da geração
19 end

```

aptidão avalia toda a população. A partir da linha 4 começa o *loop* que só acaba quando o algoritmo atingir o critério de parada. Na linha 5, os pais da próxima geração recebe uma lista vazia. Na linha 6, uma condicional indica que os passos 7, 8 e 9 estão condicionados a população não está sincronizada, o que indica um forte desequilíbrio entre as quantidades de tipos e a existência de grupos de indivíduos raros. A condicional da linha 6 também indica que os passos 7, 8 e 9 estão condicionados a população está em um Pareto único. Na linha 7, o Algoritmo 9 é chamado para selecionar z% da população para aplicação da busca local BLVMD. Vale lembrar que o Algoritmo 9 seleciona indivíduos em regiões da curva de Pareto, estimadas como pouco ocupadas, ou seja, região de indivíduos raros. Na linha 8, a busca local BLVMD, Algoritmo 4, é aplicada em z% da população selecionada

entre os indivíduos raros pelo Algoritmo 9. Na linha 9, a busca local BLBIR, Algoritmo 8, é aplicada em todas as regiões de indivíduos raros, preenchendo uma parte pequena da lista dos pais, inclusive, com todos os indivíduos aos quais a BLVMD teve êxito em melhorar. Na linha 11, o torneio binário faz a seleção dos pais (EIBEN et al., 2003), e com isso, completa a maioria das soluções na lista dos pais da maneira tradicional do NSGA-III, (DEB; JAIN, 2013). Na linha 9 e 10 os operadores evolucionários fazem a recombinação e mutação na lista de pais, onde surge a população de filhos. Na linha 14, a população de filhos passa por avaliação de aptidão. Na linha 15, uma população com o dobro do tamanho, $P(\text{dobro})$, formada pela população atual $P(T)$ mais a população dos filhos é criada. Na linha 16, a população $P(\text{dobro})$ é ordenada em frentes de Pareto pelo *fast-non-dominated-sort* Algoritmo 1, (DEB; JAIN, 2013). Na linha 17, a nova geração $P(T+1)$ recebe o retorno da seleção dos sobreviventes aplicada na população $P(\text{dobro})$ através do hiperplano normalizado. Na linha 18, o contador de tempo da geração é atualizado.

5 Metodologia

Este estudo foi realizado através de simulações de redes ópticas, todas as simulações foram feitas utilizando um lenovo Ideapad 320 processador Intel core I5, com 8Gb de memória RAM e utilizando o sistema operacional *Windows 10*. Para uso do algoritmo evolucionário NSGA-III foi usado o *framework* jmetal (NEBRO et al., 2015), um *framework* amplamente utilizado na literatura e que disponibiliza vários tipos de algoritmos evolucionários (DUPLÉIX et al., 2016; NASCIMENTO et al., 2018; CHAVES et al., 2010a). A simulação das redes ópticas foi feita com uma adaptação do simulador SIMTON (CHAVES et al., 2010b) um simulador de rede totalmente transparente usado em vários estudos (ARAÚJO et al., 2011; ARAÚJO, 2015; LIMA et al., 2016; NASCIMENTO, 2017).

5.1 Configuração do NSGA-III

O NSGA-III foi usado através do *framework* *Jmetal*, os parâmetros numéricos e simbólicos (EIBEN; SMIT, 2011a; EIBEN; SMIT, 2011b), são parâmetros de configuração de um EA. Os parâmetros de configuração numéricos e simbólicos desta pesquisa são os mesmos usados em outros artigos do gênero como (DUPLÉIX et al., 2016; FIGUEIREDO et al., 2016; NASCIMENTO, 2017; NASCIMENTO et al., 2018). Os parâmetros simbólicos são apresentados na Tabela 3.

Tabela 3 – Parâmetros simbólicos para configuração do NSGA-III.

Parâmetro	Valor
Operador de cruzamento	IntegerSBXCrossover
Operador de mutação	IntegerPolynomialMutation
Operador de seleção de pais	BinaryTournamentSelection

Já os parâmetros numéricos são apresentados na Tabela 4.

Tabela 4 – Parâmetros numéricos para configuração do NSGA-III.

Parâmetro	Valor
Probabilidade de cruzamento	1.0
Probabilidade de mutação	1/tamanho do cromossomo
Distribution Index para mutação	20
Tamanho da população	456
Distribution Index para cruzamento	20
Número máximo de avaliações de aptidão	228000
Número de execuções	10

Os parâmetros descritos nas Tabelas 2 e 3 foram obtidos de estudos empíricos ou obtidos a partir de estudos experimentais de trabalhos anteriores ([DUPLEIX et al., 2016](#); [NASCIMENTO, 2017](#); [NASCIMENTO et al., 2018](#)). O número máximo de execuções independentes teve o seu valor padrão fixado em 10 (dez) devido ao elevado tempo de execução requerido para as avaliações de rede, contudo algumas comparações críticas consideraram 30 execuções independentes. As abordagens mais promissoras foram sujeitas ao teste de hipóteses não-paramétrico de Wilcoxon ([CUZICK, 1985](#); [FAGERLAND; SANDVIK, 2009](#)).

5.2 Configuração do SIMTON.

O SIMTON ([CHAVES et al., 2010b](#)) é um simulador de redes transparentes que pode calcular a probabilidade de bloqueio de redes ópticas sobre tráfego dinâmico e considerando várias penalidades da camada física. O SIMTON já vem sendo utilizado em diversos trabalhos na literatura ([ARAÚJO, 2015](#); [NASCIMENTO et al., 2018](#); [DUPLEIX et al., 2016](#)), o SIMTON versão adaptada ([FIGUEIREDO et al., 2016](#)) foi utilizado para calcular os valores de cada uma das métricas envolvidas nesta pesquisa que foram PB, CAPEX, CA e Consumo energético.

Fonte: O autor.



Figura 16 – Layout da topologia de rede de região da MEDIANET Alemanha.

Neste trabalho o SIMTON foi usado em dois casos de estudo, o caso de estudo da MEDIANET na Alemanha e o caso de estudo usado em (NASCIMENTO et al., 2018), ou seja, uma rede que cobre a região do estado de Pernambuco (PE). A Figura 16 mostra a rede original da MEDIANET que não é um projeto de topologia de rede e sim uma rede já implantada.

Já a Figura 17, mostra um PTD apresentado nos resultados em (NASCIMENTO et al., 2018).

Fonte: O autor.




Figura 17 – Layout de topologia do PTD apresentado em (NASCIMENTO et al., 2018)

Os valores de erlangs para os dois casos de estudo diferem porque o caso de estudo da MEDIANET tem 3 nós terminais a mais que o caso de estudo de Pernambuco (PE).

Um acréscimo de nós aumenta sensivelmente o cenário em termos de possibilidades de demandas, pares origem-destino, possibilidades de rotas, e assim por diante. A Tabela 5 apresenta os parâmetros usados para configuração do simulador SIMTON, embora os parâmetros informados correspondam a uma rede WDM típica de 10 Gbps a proposta dessa dissertação poderia ser facilmente aplicada a outros conjuntos de parâmetros de redes DWDM e adaptada para redes elásticas. A parametrização do SIMTON, Tabela 5, foi baseada em trabalhos anteriores (ARAÚJO, 2015; DUPLEIX et al., 2016; NASCIMENTO et al., 2018)

Tabela 5 – Tabela de configuração do simulador de redes SIMTON.

Parâmetro	Valor	Definição
α	0,2 db/km	Coefficiente de atenuação da fibra
ΔT_{QoT}	0,1	Alargamento máximo permitido para o pulso óptico
Δf	100GHz	Espaçamento entre canais
λ_i	1528,77 nm	Primeiro comprimento de onda da grade
λ_0	1450 nm	Zero de dispersão na fibra de transmissão
λ_{0RD}	1528,77 nm	Zero de dispersão residual
B_o	100 GHz	Largura de banda do ltro
B	10 Gb/s	Taxa de transmissão
D_{DCF}	-110 ps/km.nm	Coefficiente de dispersão da fibra de compensação
D_{PMD}	$0,04ps\sqrt{km}$	Coefficiente de PMD
D_{TX}	4,5 ps/km.nm	Coefficiente de dispersão da fibra de transmissão
$Load_{PE}$	30 erlangs	Carga de tráfego da rede para Pernambuco
$Load_{MN}$	80 erlangs	Carga de tráfego da rede para MEDIANET
L_{Mux}	3 dB	Perda no multiplexador
L_{Demux}	3 dB	Perda no demultiplexador
L_{Switch}	3 dB	Perda no comutador óptico
NF	5 dB	Figura de ruído do amplificador
P_{Sat}	20 dB	Potência de saturação do amplificador
P_{TX}	3 dBm	Potência de transmissão
S_{DCF}	$-1,87ps/km.nm^2$	Slope da fibra de compensação
S_{TX}	$0,045ps/km.nm^2$	Slope da fibra de transmissão
$OSNR_{in}$	30 dB	Relação sinal-ruído óptica na entrada
$OSNR_{QoS}$	17 dB	OSNR mínima no receptor
W_{MIN}	4	Número mínimo de comprimentos de onda por enlace
W_{MAX}	40	Número máximo de comprimentos de onda por enlace

5.3 Critério de parada

O NSGA-III é tipicamente configurado por iterações (ABOUHAWWASH et al., 2017), um de seus parâmetros de configuração no Jmetal (NEBRO et al., 2015), inclusive, é o número máximo de iterações, todavia o que deixa algoritmo custoso é a função de aptidão. Este estudo teve como um de seus focos usar a busca local de uma forma que diminuísse o impacto que a avaliação de aptidão extra causada pela busca local tem sobre o processo. Por este motivo o critério de parada adotado foi o número de avaliações de aptidão que neste estudo não pode passar de 228000 avaliações. O total de 228000 avaliações de aptidão foi escolhido porque esse seria o número de avaliações de aptidão que o algoritmo faria se não fosse usada a busca local e com os parâmetros de configuração informadas na Tabela 4, além do critério de parada ser configurado como 500 iterações, o mesmo critério usado em (NASCIMENTO et al., 2018).

5.4 Configurações da Regra do *pivot* para a busca local

Esta seção descreve as regras de *pivot* estudadas neste trabalho, a Tabela 6 mostra a configuração dos experimentos de acordo com as explorações da vizinhança especificadas no Capítulo 4. Foram definidas algumas rodadas de experimentos com variações de outros aspectos de regra do *pivot* para cada uma das três configurações de exploração da vizinhança explicadas no Capítulo 4 (*Expl1*, *Expl2* e *Expl3*). A Tabela 6 mostra as configurações da regra do *pivot* para as rodadas de experimentos, na Tabela 6 cada rodada de experimentos realizou 10 execuções para 3 vizinhos em cada uma das iterações de início: 20, 120 e 220, tendo um total parcial de 30 execuções. Depois cada rodada repetiu o mesmo número de execuções para 5 vizinhos totalizando 60 execuções em cada rodada, como houve 12 rodadas totalizou 720 execuções de experimentos.

Tabela 6 – Tabela de configuração das regras do *pivot*: primeira rodada de experimentos.

Rodada	Tipo de seleção	Iteração de início	Número de vizinhos	Exploração da vizinhança	nº de indivíduos modificados pela busca local a cada iteração
1	Aleatória	20, 120 e 220	3 e 5	Expl1	4
2	Aleatória	20, 120 e 220	3 e 5	Expl2	4
3	Aleatória	20, 120 e 220	3 e 5	Expl3	4
4	Aleatória	20, 120 e 220	3 e 5	Expl1	8
5	Aleatória	20, 120 e 220	3 e 5	Expl2	8
6	Aleatória	20, 120 e 220	3 e 5	Expl3	8
7	Indivíduo raro	20, 120 e 220	3 e 5	Expl1	4
8	Indivíduo raro	20, 120 e 220	3 e 5	Expl2	4
9	Indivíduo raro	20, 120 e 220	3 e 5	Expl3	4
10	Indivíduo raro	20, 120 e 220	3 e 5	Expl1	8
11	Indivíduo raro	20, 120 e 220	3 e 5	Expl2	8
12	Indivíduo raro	20, 120 e 220	3 e 5	Expl3	8

Todas as execuções da Tabela 6 foram realizadas usando a busca local BLVMD, após as execuções expostas na Tabela 6 foram feitas mais 10 execuções da abordagem que apresentou o melhor resultado. Todavia, essas 10 execuções a mais foram realizadas com um *upgrade* na abordagem, pois o indivíduo que conseguia ser melhorado pela busca local entrava imediatamente na população dos pais, porém, essa *upgrade* ainda não era a aplicação da BLBIR e sim apenas um privilégio do melhorado na população dos pais. Após esse experimento com privilégios na população dos pais para o indivíduo melhorado pela BLVMD foi realizado mais um novo experimento fazendo um segundo *upgrade* na abordagem, o novo experimento realizou mais 10 execuções da abordagem campeã, agora sim, adicionada da segunda busca local que não tem custo computacional referente a uma nova avaliação de aptidão A BLBIR.

Por fim, como último experimento, foram realizadas mais 30 execuções da abordagem campeã com as duas buscas locais e mais 30 execuções da abordagem usada em (NASCIMENTO et al., 2018). Na abordagem de (NASCIMENTO et al., 2018) a busca local é aplicada em todos os indivíduos desde o início da execução do algoritmo até o final, considerando 3 vizinhos com a exploração igual a *Expl1*. Esse último experimento foi realizado tanto para o cenário de Pernambuco quanto para o cenário da *MEDIANET*.

As diferentes abordagens propostas nessa dissertação foram comparadas em termos

de HV, tanto avaliando a estatística descritiva do HV em momentos específicos quanto observando o gráfico de convergência/evolução da métrica. É importante destacar que a curva de evolução de HV costuma evoluir de forma sinuosa ([ABOUHAWWASH et al., 2017](#); [NASCIMENTO et al., 2018](#)), contudo, para facilitar a leitura dos gráficos e dar mais clareza nas comparações, os gráficos de convergência de HV são apresentados em função do valor médio das diversas execuções e é mantido o patamar mais elevado até o ponto considerado do gráfico.

6 Resultados

Este capítulo apresentará os resultados dessa pesquisa, primeiro serão apresentados os gráficos da etapa que foi classificada como uma primeira etapa de análises, uma etapa onde diversas abordagens foram comparadas de forma que fosse encontrado uma abordagem mais promissora. Foram feitos conjuntos de experimentos de 10 execuções para que rapidamente se encontrasse uma abordagem mais promissora. Resumindo, será apresentado um compilado dos resultados dos experimentos onde as configurações constam na Tabela 6. Após demonstração do compilado de resultados sobre a primeira etapa experimental, foi escolhido uma abordagem mais promissora. Essa abordagem foi combinada com as técnicas de multiplicação de resultados desenvolvidos neste estudo, então foram feitos experimentos considerando 30 execuções independentes das propostas mais promissoras. A comparação final foi feita com a abordagem tratada em (NASCIMENTO et al., 2018) onde a regra do *pivot* era aplicar a busca local em todos os indivíduos da população e desde o início das iterações, esses experimentos serão apresentados por último.

Das várias abordagens experimentadas que constam na Tabela 6 serão apresentadas 14 abordagens neste capítulo e elas serão descritas ao longo do texto, todavia, a Tabela 7 mostra uma síntese da configuração de regra do *pivot* de cada uma das 14 abordagens.

Tabela 7 – Tabela da descrição da regra do *pivot* das abordagens apresentadas nos resultados.

Abordagem	Tipo de seleção	Iteração de início	Número de cidades consideradas vizinhos mais próximos	Exploração da vizinhança	Nº de indivíduos modificados pela busca local a cada iteração	Estratégia de multiplicação de melhoramentos
AB1	Aleatória	120	3	Expl1	4	-
AB2	Aleatória	220	5	Expl1	4	-
AB3	Aleatória	20	3	Expl1	8	-
AB4	Aleatória	120	3	Expl1	8	-
AB5	Aleatória	20	5	Expl3	4	-
AB6	Aleatória	20	5	Expl3	8	-
AB7	Indivíduo raro	220	3	Expl1	4	privilégio na população dos pais
AB8	Indivíduo raro	20	5	Expl1	4	-
AB9	Indivíduo raro	20	3	Expl3	8	-
AB10	Indivíduo raro	220	5	Expl3	8	-
AB11	Indivíduo raro	20	5	Expl3	8	privilégio na população dos pais
AB12	Indivíduo raro	20	5	Expl3	8	BLBIR
AB12	Indivíduo raro	20	5	Expl3	8	BLBIR
AB13	Indivíduo raro	20	3	Expl2	4	-
AB14	busca em todos	1	3	Expl1	8	-
AB12 MEDIANET	Indivíduo raro	20	5	Expl3	8	BLBIR
AB14 MEDIANET	busca em todos	1	3	Expl1	8	-

6.1 Resultados da abordagem de escolha aleatória

Nesta seção serão apresentados os resultados relativos à abordagem que seleciona a solução em meio a população de soluções de forma aleatória para aplicação da busca local. Vários tipos de exploração da vizinhança foram usadas e constam no Capítulo 5. O cenário tratado nesta seção será o de Pernambuco, na Seção 6.4, será mostrado um

experimento para o cenário da MEDIANET.

A Figura 18 mostra a estatística descritiva de 10 execuções do experimento de duas regras do *pivot* para a abordagem de seleção de indivíduos na população de forma aleatória. Na Figura 18, as regras do *pivot* para os dois casos incluem a cada iteração a seleção de 4 indivíduos aleatoriamente em meio a população, a exploração da vizinhança foi seguindo a exploração Expl1, porém, as iterações de início da busca local e a quantidade de vizinhos considerados são diferentes para cada uma das duas abordagens.

Fonte: o autor.




Figura 18 – Comparação entre a AB 1 e a AB 2 duas abordagens com exploração da vizinhança Expl1.

A Expl1 sorteia o vizinho entre os vizinhos mais próximos e só examina o sorteado. A Figura 18A mostra o desenvolvimento da média do *hypervolume* HV, para as 10 execuções de cada abordagem ao longo da evolução pelos marcos de avaliação de aptidão. Na Figura 18A os triângulos azuis, AB 1, representam a abordagem onde a busca local começou na iteração 120 e considerou 3 cidades mais próximas como cidades vizinhas. Já os círculos vermelhos, AB 2, representam a evolução do HV para a abordagem que começou a busca local na iteração 220 e considerou 5 cidades mais próximas como cidades vizinhas. A Figura 18B mostra o Box-plots para as 10 execuções de cada abordagem no momento da avaliação de aptidão 127680.

Com os valores de HV muito próximos ao longo da evolução, como mostra a Figura 18A, as duas abordagens mostram mais equivalência do que vantagem uma sobre a outra. Com os valores máximos de HV que não ultrapassam 0,685, limite máximo este observado em vários experimentos desse estudo, as duas abordagens não mostraram diferenças significativas. A única diferenciação que pode sugerir uma escolha entre as duas abordagens está no o box-plot da Figura 18B, na Figura 18B a abordagem AB 1 mostra

uma caixa mais compacta que a *AB 2* e a caixa das duas abordagens estão quase niveladas por cima. O resultado da Figura 18B mostra que a *AB 1*, estatisticamente, teve execuções mais confiáveis em torno de um mesmo valor de HV que a *AB 2*.

A Figura 19 mostra a estatística descritiva de 10 execuções para outras duas abordagens experimentadas neste trabalho que também tem seleção de indivíduos para aplicação da busca local de forma aleatória. Das duas abordagens da Figura 19, ambas selecionam 8 indivíduos a cada iteração para aplicar a busca local. Também foram considerados o mesmo número de cidades vizinhas como cidades mais próximas para as duas abordagens, 3 cidades. A exploração da vizinhança foi a exploração Expl1, todavia, as iterações de início foram diferentes, na Figura 19A os triângulos azuis representam a abordagem *AB 3*, que inicia a busca local na iteração 20, enquanto que, os círculos vermelhos representam a abordagem *AB 4* que inicia a busca local na iteração 120.

Fonte: o autor.




Figura 19 – Comparação entre a *AB 3* e a *AB 4* duas abordagens com exploração da vizinhança Expl1.

Já a Figura 19B mostra o gráfico box-plot das 10 execuções no momento de avaliação de aptidão 127680. Similar ao resultado mostrado na Figura 18 os resultados da Figura 19 sugerem equivalência, e até mais, porque no caso da Figura 19B a diferença de compactidade entre a *AB 3* e a *AB 4* diminuem em relação as abordagens da Figura 18B e o nivelamento não está tão pela parte superior da caixas.

A Figura 20 mostra a abordagem mais promissora para a seleção de indivíduos de forma aleatória em meio a população de soluções para aplicação da busca local. Na Figura 20, está a estatística descritiva para as 10 execuções de duas abordagens que selecionam números diferentes de indivíduos para aplicação da busca local por iteração, mas, que começam a aplicação da busca local na mesma iteração, a iteração 20.

Fonte: o autor.




Figura 20 – Comparação entre a AB 5 e a AB 6 duas abordagens com exploração da vizinhança Expl3.

Na Figura 20A, os triângulos azuis representam a abordagem AB 5 que seleciona 4 indivíduos por iteração desde a iteração 20. Já os círculos vermelhos mostram a abordagem AB 6 que seleciona 8 indivíduos a partir da iteração 20. Todavia, as duas abordagens usam a regra do *pivot* para exploração da vizinhança mais efetiva estudada neste trabalho, a Expl3, que explora a vizinhança por exaustão, explorar a vizinhança por exaustão significa explorar toda a vizinhança delimitada em busca da melhor, entre as melhores, opção de solução. É possível observar que a AB 6 passa estatisticamente do limiar de 0,69 de HV, quando o que foi observado neste pesquisa foi que o HV de 0,685 foi o limite máximo de várias abordagens. Na Figura 20B, observa-se que as caixas de box-plot têm basicamente a mesma compactidade o que indica que as duas abordagens têm a mesma margem de confiança em torno de seus respectivos valores de HV. Todavia, a AB 6 encontra-se mais deslocada para cima do que a AB 5 o que tornaria a AB 6 uma escolha melhor para uma ferramenta, por exemplo. Porém, a AB 6 não é totalmente superior a AB 5, ou seja, houveram execuções na AB 5 que foram superior a uma ou outra execução da AB 6. Para este par de experimentos mostrou-se melhor a AB 6, e, a AB 6 se mostrou a abordagem mais promissora da estratégia de seleção de indivíduos de forma aleatória.

A Figura 21 mostra o gráfico de coordenadas paralelas da execução que mais ficou próximo a média de 0,6861 de HV para a abordagem AB 5 e de 0,6930 de HV para a abordagem AB 6 da Figura 20B. Na Figura 21, as marcações representam:

- 1 - Representa a probabilidade de bloqueio PB.
- 2 - Representa o valor normalizado do CAPEX.
- 3 - Representa o valor normalizado do Consumo energético.
- 4 - Representa o valor normalizado da Conectividade Algebrica CA.

Fonte: o autor.




Figura 21 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens *AB 5* e *AB 6*.

As linhas coloridas mostram as soluções que obtiveram melhor avaliação em cada um dos objetivos do problema, em problemas de minimização quanto menor melhor.

A abordagem mais promissora da Figura 20 é a *AB 6*, todas as soluções da abordagem *AB 6* estão plotadas no gráfico de coordenadas paralelas da Figura 21B que representa o Pareto. Dentre essas soluções que são projetos de topologias de rede, PTD, a topologia de melhor CA teve sua rede plotada no mapa do estado de Pernambuco. A Figura 22 mostra essa rede, que tem a PB igual a 0,060, o CAPEX igual a 14632,669 u.m, o Consumo energético igual a 166074,330 kW e a Conectividade algébrica igual a 0,141, todavia o espaço de busca da CA pode melhorar (ARAÚJO, 2015).

Fonte: o autor.




Figura 22 – PTD com melhor CA para a abordagem *AB 6*.

Para finalizar a seção é importante mencionar que, embora não tenha sido percebido uma grande variação quantitativa nos resultados entre *AB 1-AB 4*, era importante avaliar o impacto deste tipo de intervenção antes de analisar as outras estratégias de busca local

mais promissoras cujos resultados serão mostrados nas próximas subseções.

6.2 Seleção no grupo de indivíduos raros

Esta seção mostrará os gráficos relativos à abordagem que seleciona indivíduos, para aplicar a busca local, no grupo de indivíduos raros. A técnica de seleção de indivíduos raros para aplicação da busca local foi pensada de forma gradativa. A ideia inicial era melhorar as soluções em localização estimadas da curva de Pareto onde não houvesse muitas soluções, e assim, melhorar a convergência ao ponto que se melhorava a distribuição. Todavia, as primeiras abordagens não se mostraram muito diferentes da abordagem que seleciona indivíduos aleatoriamente, o que ratifica o que é expressado na literatura sobre o momento em que a população assume um Pareto único, (ABOUHAWWASH et al., 2017; ZHOU; WANG, 2014), e que está descrito na Seção 4.2. As abordagens trabalhadas serão mostradas nesta seção desde as primeiras até as que fizeram a proposta apresentar resultados significativos e com maior impacto.

A Figura 23 mostra a estatística descritiva de 10 execuções de duas abordagens onde as regras do *pivot* para cada uma, seleciona 4 indivíduos raros para aplicação da busca local. A diferença entre suas regras do *pivot* é a iteração de início e a quantidade de cidades vizinhas consideradas, entretanto, ambas usam a exploração da vizinhança Expl1.

Fonte: o autor.




Figura 23 – Comparação entre AB 7 e AB 8 duas abordagens com exploração da vizinhança Expl1.

A Figura 23A mostra a evolução do HV das duas abordagens, na Figura 23A os círculos vermelhos mostram a AB 7, uma abordagem que considera 3 cidades como cidades mais próximas e começa a aplicação da busca local na iteração 220. Já os triângulos azuis

mostram a *AB 8*, uma abordagem que considera 5 cidades como cidades mais próximos e inicia as buscas na iteração 20. A Figura 23B mostra o box-plot das 10 execuções de cada uma das duas abordagens.

Um outro detalhe é que, apesar da exploração da vizinhança ser a menos custosa e também menos efetiva, Expl1, o que teoricamente enfraqueceria a abordagem, as duas abordagens estão usando a menos efetiva das estratégias de multiplicação dos melhoramentos. Na estratégia de multiplicação de melhoramentos usada, o indivíduo melhorado com sucesso pela busca local entra imediatamente na população dos pais. O fato de a exploração ser a menos efetiva, Expl1, anulou um pouco essa estratégia de multiplicação de melhoramento de resultados. Com isso, apenas uma sutil melhora de evolução de HV foi observado em uma das evoluções da Figura 23A que, estatisticamente, passou apenas um pouco de 0,685 de HV, mas sem muita expressividade.

Observa-se outro caso de equivalência no experimento da Figura 23, inclusive, com os experimentos seguindo a exploração Expl1 da Seção 6.1, onde os indivíduos são escolhidos aleatoriamente na população. E em relação ao box-plot Figura 23B, se por um lado a caixa da *AB 7* é mais compacta que a *AB 8* por outro é mais baixa, o nivelamento inclusive ficou quase que sendo pela parte de baixo das caixas.

A Figura 24 mostra a estatística descritiva de outras duas das abordagens usadas para indivíduos raros. A partir dessa abordagem já é possível perceber o ganho que a seleção de indivíduos raros proporciona.

Fonte: o autor.




Figura 24 – Comparação entre *AB 9* e *AB 10* duas abordagens com exploração da vizinhança Expl3.

Na Figura 24A os triângulos azuis mostram a abordagem *AB 9* onde a regra do *pivot* a partir da iteração 20, seleciona 8 indivíduos por iteração no grupo de indivíduos raros

para aplicação da busca local. Na abordagem *AB 9* a regra do *pivot* também considera 3 cidades como cidades mais próximas e a exploração da vizinhança é por exaustão, a Expl3. Já os círculos vermelhos mostram a abordagem *AB 10* na qual a regra do *pivot*, a partir da iteração 220, seleciona 8 indivíduos raros por iteração para aplicação da busca local. Na *AB 10*, também se considera 5 cidades como cidades mais próximas e a exploração da vizinhança é por exaustão, Expl3. A diferença entre as duas abordagens é que a *AB 9* começa a aplicação da busca local logo na iteração 20, mas, só considera 3 cidades como cidades mais próximas. Já a *AB 10* começa a aplicação da busca local na iteração 220 e considera 5 cidades como cidades mais próximas.

O que se vê na Figura 24A é que a abordagem que aplicou a busca local logo nas primeiras iterações, apesar de considerar uma vizinhança menor foi mais rápida. Logo na avaliação de aptidão 109440 a *AB 9* conseguiu chegar ao seu ápice, enquanto a *AB 10* só alcançou a mesmo patamar de HV na avaliação de aptidão 191520. Os dois retângulos pretos interligados por uma linha tracejada, na Figura 24A, marcam os pontos de alcance de ápice das duas abordagens. Na Figura 24B o gráfico de box-plot para as duas abordagens é apresentado, foi realizado um teste de Wilcoxon para os dois conjuntos de dados das abordagens *AB9* e *AB10* e a hipótese nula de que a mediana dos dois conjuntos de dados é igual foi rejeitada com $p < 5\%$, ou seja, a abordagem *AB9* realmente é superior com nível de confiança de 95%.

Uma outra observação sobre a Figura 24A é que o limiar estatístico de 0,69 de HV alcançado pela *AB 6* da Figura 20 ficou para trás, pois, as duas abordagens *AB 9* e *AB 10* passaram de 0,695 de HV.

Na Figura 24B, as caixas da *AB 9* e *AB10* têm praticamente a mesma compacidade, todavia, na *AB 9* a caixa está mais deslocada pra cima o que mostra a sua superioridade. O desempenho melhor da *AB 9* em relação a *AB 10* se deu porque apesar de explorar uma vizinhança menor, a *AB 9* iniciou a aplicação da busca local logo nas primeiras iterações, na iteração 20. Todavia, é importante destacar que nas observações dos experimentos dessa pesquisa, na iteração 20 todos os indivíduos já estavam em um Pareto único. O que foi uma estratégia adotada para a questão da iteração de início da aplicação da busca local no intento de evitar prisões em máximos locais (LINDEN, 2008). Entretanto, nenhuma das duas abordagens da Figura 24 usou quaisquer das estratégias de multiplicação de melhorias desenvolvidas nesse trabalho, o que levantou a questão de como ficaria os resultados se

usassem as estratégias.

A Figura 25 mostra o gráfico de coordenadas paralelas da execução que mais ficou próximo a média de 0,6957 de HV para a abordagem AB 9 e de 0,6866 de HV para a abordagem AB 10 da Figura 24.

Fonte: o autor.




Figura 25 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens AB 9 e AB 10.

Da Figura 25A, foi selecionado o PTD com menor custo de implantação, CAPEX, para ser apresentado, a Figura 26 mostra o PTD.

Fonte: o autor.




Figura 26 – PTD com melhor CAPEX para a abordagem AB 10.

No PTD da Figura 26, as métricas de objetivos medidas para essa topologia foram de Probabilidade de bloqueio, PB, igual a 0,552181, custo com implantação, CAPEX, igual a 1468,92, Consumo energético em kW igual a 40293,91 kW, e por fim, Conectividade algébrica CA igual a 0,756. Embora uma rede óptica com $PB > 0,01$ não seja uma solução prática, esse conjunto de objetivos ilustra bem o compromisso obtido pelo AE relacionado

com esta abordagem.

No próxima demonstração de experimentos será usado a *AB 9*, abordagem campeã do experimento da Figura 24, contra um outro experimento que fez um *upgrade* nas regras do *pivot* na *AB 9*: aumento do limite de vizinhança e aplicação da menos efetiva das estratégias de multiplicação dos melhoramentos. A estratégia de melhoramento que apenas privilegia na população dos pais, o indivíduo melhorado com sucesso pela busca local.

A Figura 27, mostra a estatística descritiva da *AB 9*, campeã da Figura 24, sendo comparada com um outro experimento que pode ser visto como um upgrade para a *AB 9*.

Fonte: o autor.




Figura 27 – Comparação de duas abordagens *AB 9* e *AB 11* duas abordagens para exploração Expl3.

A *AB 11*, Figura 27, tem as regras do *pivot* um pouco diferente da *AB 9*, na *AB 11*, representada pelos círculos vermelhos na Figura 27A, a busca local também começa a ser aplicada na iteração 20 e a exploração é por exaustão (Expl3), exatamente como na *AB 9*. Todavia, o número de cidades consideradas como cidades mais próximas aumentam, passam a ser 5 cidades. Uma outra diferença é que a estratégia de multiplicação de melhoramentos que privilegia o indivíduos melhorado pela busca local na população dos pais, também é usada na *AB 11*.

O resultado é que a *AB 11* superou a *AB 9*, mas com um melhoramento pouco expressivo, porém, o melhoramento existiu. A Figura 27A mostra que o HV da *AB 11* foi superior, quase alcançando o HV de 0,70, mas, a Figura 27B sugere equivalência, porém o experimento *AB11*, apesar de não mostrar diferenças significativas em relação ao *AB9* foi importante de ter sido realizado para se entender se uma excitação pequena na população proporcionada por uma estratégia de multiplicação de resultados considerada pouco efetiva

conseguiria surtir algum efeito na melhoria da população. O fato de ter conseguido surtir algum efeito, mesmo que pequeno, mostrou um indicativo de que a BLBIR que contém uma estratégia de multiplicação de resultados mais efetiva iria provocar uma melhora maior. A próxima demonstração de experimentos mostrará o que acontece se for aplicado a estratégia de multiplicação de melhorias mais expressiva deste trabalho, a BLBIR.

A BLBIR foi descrita na Seção 4.6, a BLBIR é uma busca local que não acrescenta custo computacional relativo a uma nova avaliação de aptidão e é a estratégia de multiplicação de melhoramentos mais efetiva desse estudo. A BLBIR também melhora a distribuição da população, aliás, a BLBIR é uma busca local focada na distribuição da população.

A Figura 28 mostra a estatística descritiva para a abordagem *AB 11*, apresentada na Figura 27 e a abordagem a *AB 12*, a abordagem *AB 12* é a abordagem *AB 11* acrescida da BLBIR. Todavia, o experimento foi realizado com 30 execuções porque a abordagem se mostrava a mais promissora e era importante analisar melhor o seu comportamento estatístico, a Figura 28 mostra a realização do experimento com 30 execuções.

Fonte: o autor.




Figura 28 – Comparação entre *AB 11* e *AB 12* duas abordagens com exploração da vizinhança Expl3 - 30 execuções. .

Na Figura 28A, os triângulos azuis são a abordagem *AB 11* e os círculos vermelhos a *AB 12*. É possível observar que a média dos valores de HV encontrados pela *AB 12* no terceiro marco de avaliação de aptidão, avaliação de aptidão 27360 e equivalente a iteração 60, só são alcançados pela *AB 11* no sétimo marco de avaliação de aptidão, ou seja, avaliação de aptidão 63840 e equivalente a interação 140, os dois círculos pretos interligados por uma linha preta tracejada mostram o marco de avaliação de aptidão onde isso ocorre. Todavia, no quarto marco de avaliação de aptidão, avaliação 36480, a *AB 12*

alcança valores de HV nunca alcançados pela *AB 11*, o quadrado preto de onde sai uma linha preta tracejada mostra o marco de avaliação de aptidão onde isso acontece.

O valor máximo de HV encontrado pela *AB 12* para este experimento foi de 0,7142 e o máximo da *AB 11* foi de 0,6942. A Figura 28B mostra o gráfico box-plot para as 30 execuções das duas abordagens no momento de avaliação de aptidão 145920 avaliações, momento em que a *AB 12* assume seu ápice para este experimento, na Figura 28B, a caixa da *AB 12* está bem mais deslocada para cima em relação a caixa da *AB 11*. Esses resultados qualificam a *AB 12* como abordagem mais promissora deste estudo, foi realizado um teste de Wilcoxon para os dois conjuntos de dados das abordagens *AB11* e *AB12* e a hipótese nula de que a mediana dos dois conjuntos de dados é igual foi rejeitada com $p < 5\%$, ou seja, a abordagem *AB12* realmente é superior com nível de confiança de 95%.

6.3 Abordagem mais promissora *versus* a menos promissora e as regras do *pivot* de (NASCIMENTO et al., 2018)

Nesta seção será apresentado a comparação entre a abordagem mais promissora e a menos promissora, pode-se dizer que as abordagens menos promissoras desta pesquisa foram as abordagens que usam a forma de exploração da vizinhança Expl2, que explora a vizinhança até encontrar um dominante e para. Essa abordagem se mostrou igualmente ruim, tanto para seleção de indivíduos raros quanto para a seleção de indivíduos aleatória em meio a população para aplicação da busca local. Os experimentos mostraram que independente das variações de regra do *pivot* aqui propostas: tipo de seleção de indivíduo; número de indivíduos selecionados para a aplicação da busca local; número considerado de vizinhos ou da iteração de início, a exploração da vizinhança Expl2 provocou uma espécie de travamento na evolução da população para os experimentos no PTD deste estudo.

Nesta seção também será feita a comparação entre a abordagem mais promissora deste estudo, frente as regras do *pivot* usadas em (NASCIMENTO et al., 2018). As comparações dessa seção são muito importantes para este estudo, portanto, haverá duas subseções uma para cada foco.

6.3.1 A abordagem mais promissora *versus* a menos promissora

A Figura 29, mostra a estatística descritiva para 10 execuções da abordagem mais promissora, a *AB 12*, e a abordagem menos promissora, a *AB 13*.

Fonte: o autor.




Figura 29 – Comparação entre *AB 13* e *AB 12* uma abordagem com exploração da vizinhança Expl2 e outra com Expl3.

Na Figura 29A, os triângulos azuis representam a abordagem *AB 12* que seleciona 8 indivíduos por iteração entre o grupo de indivíduos raros. A *AB 12* começa a aplicar a busca local na iteração 20 e considera 5 cidades como cidades mais próximas e explora a vizinhança por exaustão, Expl3, além de usar a BLBIR. Os círculos vermelhos representam a abordagem *AB 13* que seleciona 4 indivíduos por iteração entre os indivíduos raros, com a exploração Expl2, considerando 3 vizinhos e aplica a busca local a partir da iteração 20. Se por um lado o que alavancou a *AB 12* foi a mescla de aplicação da busca local em indivíduos raros com a exploração Expl3 e o auxílio da BLBIR, por outro lado o que travou a evolução da *AB 13* foi o uso da Exp2 logo nas iterações iniciais.

A Figura 29A mostra que estatisticamente, há uma melhora de 5,57% entre a *AB 12* e a *AB 13*, enquanto a Figura 29B mostra que a *AB 12* é totalmente superior a *AB 13*, o que significa que nenhuma das 10 execuções da *AB 13* conseguiu se igualar a pelo menos uma execução da *AB 12*, portanto, o teste de estatístico é desnecessário para averiguar se a *AB12* é de fato melhor que a *AB13*.

6.3.2 A abordagem mais promissora *versus* as regras do *pivot* de (NASCIMENTO et al., 2018)

A Figura 30 mostra a estatística descritiva para 30 execuções da abordagem mais promissora deste estudo sendo comparada com 30 execuções da abordagem que usa as regras do *pivot* praticadas em (NASCIMENTO et al., 2018). Todavia, para não haver injustiças já que a busca local elaborada em (NASCIMENTO et al., 2018) não tinha influência sobre a CA, neste experimento as buscas locais especificamente para o PTD usadas nas duas abordagens é a mesma busca, a BLVMD, apresentada neste trabalho. A premissa é que priorizar refinamento em detrimento da exploração causa um travamento na evolução da população para um PTD.

Fonte: o autor.




Figura 30 – Comparação entre *AB 12*, com Expl3 e *AB 14* com Expl1, a abordagem de (NASCIMENTO et al., 2018).

Na Figura 30A, os triângulos azuis mostram a abordagem *AB 12* já apresentada na Seção 6.2 e que foi considerada a abordagem mais promissora deste estudo. Já os círculos vermelhos mostram uma abordagem *AB 14* que usa as regras do *pivot* de (NASCIMENTO et al., 2018): aplicação da busca local em todos os indivíduos da população, desde o início das iteração e até o fim da execução, o número de cidades selecionadas como cidades mais próximas é 3 e a exploração da vizinhança é a Expl1, exatamente como em (NASCIMENTO et al., 2018).

Na Figura 30A, está a evolução do HV das duas abordagens *AB 14* e *AB 12*, já no terceiro ponto marco de avaliação de aptidão, avaliação 27360, a *AB 12* alcança 0,6884 de HV, esse valor não é alcançado pela *AB 14* e só no vigésimo marco de avaliação de aptidão, avaliação 182400, a abordagem consegue alcançar o HV de 0,6845, valor que fica mais próximo do terceiro marco da *AB 12*. Os dois quadrados pretos interligados por uma

reta tracejada preta mostram os marcos destacados. Porém, a *AB 12* não para de evoluir atingindo seu ápice no décimo sexto marco de avaliação de aptidão, avaliação 145920, onde alcança o HV de 0,7142. Ou seja, em termos estatísticos, a Figura 30A mostra que a *AB 12*, além de ser mais rápida que a *AB 14* ainda é bem mais eficaz.

A Figura 30B mostra o gráfico box-plot para as 30 execuções de cada abordagem, a caixa da *AB 14* está bem mais para baixo que a caixa da *AB 12*, o que significa que a *AB 12* é superior. Além do mais, uma informação importante que se pode notar deste gráfico é justamente o efeito que o refinamento excessivo provoca, pode-se observar que a caixa da *AB 14* não sobe, porém, os resultados das 30 execuções ficaram bem compactados em torno de uma mesma região de HV, o que sem a elevação da caixa não demonstra boa eficiência. Também foi realizado um teste de Wilcoxon para os dois conjuntos de dados das abordagens *AB12* e *AB14* e a hipótese nula de que a mediana dos dois conjuntos de dados é igual foi rejeitada com $p < 5\%$, ou seja, a abordagem *AB12* realmente é superior com nível de confiança de 95%.

A Figura 31 mostra dois gráficos de coordenadas paralelas que representam as frentes de Pareto para o momento fotografado pelo box-plot da Figura 30B. As duas frentes de Pareto representadas pela Figura 31 são as frentes de Pareto das execuções que mais se aproximaram das respectivas médias para as 30 execuções de cada abordagem na Figura 30B.

Fonte: o autor.




Figura 31 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens *AB 14* e *AB 12*.


A Figura 31A representa o Pareto com HV de 0,6817 que foi o Pareto que mais se aproximou da média de 0,6818 de HV das 30 execuções da *AB 14*. Já a Figura 31B representa o Pareto com HV de 0,7138 que foi o Pareto que mais se aproximou da média de

0,7142 de HV das 30 execuções da *AB 12*. Cada reta colorida dos gráficos de coordenadas paralelas representa uma das soluções que atingiu a melhor avaliação em um dos objetivos.

Para o PTD a probabilidade de bloqueio é uma métrica muito importante, por isso se gasta tanto esforço computacional para calcular essa métrica. É bem discutido na literatura que é importante uma abordagem encontrar algum PTD com PB menor que 0,01 ([NASCIMENTO et al., 2018](#); [DUPLEIX et al., 2016](#)). Nas abordagens trabalhadas neste estudo vários PTDs com PB menor que 0,01 foram encontrados, inclusive nas abordagens *AB 12* e *AB 14*. A Figura 32 mostra um PTD para o estado de Pernambuco com PB menor que 0,01 para a abordagem *AB 14*, e outro PTD também para o estado de Pernambuco com PB menor que 0,01 para a abordagem *AB 12*.


Fonte: o autor.

A) UM PTD da abordagem *AB 14*



PB: 0,00579
CAPEX: 12302,877 u.m.
Consumo energético: 230493,208 KW
Conectividade Algébrica: 0,315

B) UM PTD da abordagem *AB 12*



PB: 0,00563
CAPEX: 9269,266 u.m.
Consumo energético: 203972,063 KW
Conectividade Algébrica: 0,328.

Figura 32 – Exemplos de PTDs com melhor PB para as abordagens *AB 14* e *AB 12*.

A Figura 32A mostra um PTD para *AB 14*, os valores de métricas alcançados foram PB 0,00579, CAPEX 12302,877 u.m, Consumo energético 230493,208 kW e Conectividade Algébrica 0,315. Já a Figura 32B mostra um PTD para a abordagem *AB 12*, os valores de métricas obtidos foram PB 0,00563, CAPEX 9269,266 u.m, Consumo energético 203972,063 kW e Conectividade Algébrica 0,328. Ou seja, um PTD com a probabilidade de bloqueio menor e ainda assim, um PTD mais barato para implantar que o da abordagem *AB 14*. O PTD da abordagem *AB 12* também é mais barato para manter que o PTD da abordagem *AB 14*, já que tem um consumo energético menor.

6.4 Resultados para o cenário MEDIANET

É interessante avaliar o impacto das abordagens meméticas desta dissertação quando aplicadas a diferentes coberturas geográficas. Esta seção apresenta os resultados da proposta quando aplicada ao cenário de projeto de uma rede regional para Alemanha, cobrindo a área geográfica original da rede MEDIANET (ARAÚJO, 2015).

Para esse experimento, as abordagens *AB 12* e *AB 14* foram chamados de *AB 12 MEDIANET* e *AB 14 MEDIANET*. A premissa foi que poderia haver variações, mas, o resultado final se assemelharia ao do cenário de Pernambuco. A abordagem *AB 14 MEDIANET*, abordagem praticada em (NASCIMENTO et al., 2018), foi aplicada exatamente como no experimento *AB 14* seguindo a exploração da vizinhança Expl1. Todavia, por questão de experimentar maiores variações de estratégias, a vizinhança foi aumentada para 5 vizinhos e não apenas 3.

É importante observar que os nós terminais para o PTD, aqui desenhado, não são os nós terminais originais da MEDIANET, e sim os nós terminais decididos em tempo de execução pela técnica de (NASCIMENTO et al., 2018).

Fonte: o autor.




Figura 33 – Comparação entre *AB 12* e *AB 14* em outro cenário de experimentos: a rede de região MEDIANET.

A Figura 33 mostra a estatística descritiva de 30 execuções para a *AB 12 MEDIANET* e a *AB 14 MEDIANET*. Na Figura 33A, os triângulos azuis representam a abordagem *AB 12 MEDIANET* e os círculo vermelhos representam a *AB 14 MEDIANET*. É possível observar que de forma idêntica ao cenário de Pernambuco a abordagem *AB 12 MEDIANET* de forma muito rápida, em termos estatisticamente, atinge valores de HV que não são atingidos pela *AB 14 MEDIANET*. Neste cenário da MEDIANET inclusive,

esse alcance rápido de HV aconteceu logo no segundo marco de avaliação de aptidão, na avaliação de aptidão 18240 a *AB 12* MEDIANET, estatisticamente, chegou a 0,7190 de HV o valor mais próximo aos estatísticos 0,7190 que a abordagem *AB 14* MEDIANET atingiu foi de 0,7180 de HV, e só no último marco de avaliação de aptidão, na avaliação 228000. Na Figura 33A Os dois quadrados pretos interligados por uma reta tracejada apontam os marcos de avaliação de aptidão onde a proximidade aconteceu. Entretanto, a *AB 12* MEDIANET não para de evoluir até chegar ao se ápice estatístico de 0,7282 de HV.

A Figura 33B mostra o gráfico de box-plot para as 30 execuções de cada abordagem, semelhante ao cenário e Pernambuco o efeito do refinamento excessivo compactou bastante a caixa da abordagem *AB 14* MEDIANET, porém, mais uma vez sem deixar ela subir, já a caixa da *AB 12* MEDIANET subiu bem mais que a da abordagem *AB 14* MEDIANET. Foi realizado um teste de Wilcoxon para os dois conjuntos de dados das abordagens *AB 12* MEDIANET e *AB 14* MEDIANET e a hipótese nula de que a mediana dos dois conjuntos de dados é igual foi rejeitada com $p < 5\%$, ou seja, a abordagem *AB 12* MEDIANET realmente é superior com nível de confiança de 95%. Os resultados da *AB 12* MEDIANET e da *AB 14* MEDIANET, portanto, ratificam o que aconteceu com a *AB 12* e a *AB 14*, validando assim, a premissa de que poderiam haver variações nos resultados, mas, o resultado final se assemelharia ao do cenário de Pernambuco.

A Figura 34 mostra dois gráficos de coordenadas paralelas que representam os Paretos para o momento fotografado pelo box-plot da Figura 33B. Os dois Paretos representados pela Figura 34 são os Paretos das execuções que mais se aproximaram das respectivas médias das execuções da Figura 33B.

A Figura 34A representa o Pareto com HV de 0,7167, que foi o Pareto que mais se aproximou da média de 0,7167 de HV das 30 execuções da *AB 14* MEDIANET. Já a Figura 34B representa o Pareto com HV de 0,7285, que foi o Pareto que mais se aproximou da média de 0,7281 de HV das 30 execuções da *AB 12* MEDIANET.

A Figura 35 mostra dois exemplos de PTD com a PB menor que 0,01 para as abordagens *AB 14* MEDIANET e *AB 12* MEDIANET. A Figura 35A mostra um PTD para a abordagem *AB 14* MEDIANET com PB de 0,00994, CAPEX de 6016,584 u.m, Consumo energético de 283459,782 kW e conectividade algébrica de 0,289.

Já a Figura 35B mostra um PTD para a abordagem *AB 12* com PB de 0,00990,

Fonte: o autor.




Figura 34 – Gráfico de coordenadas paralelas que representa o Pareto das abordagens *AB 12* e *AB 14* no cenário da MEDIANET

Fonte: o autor.




Figura 35 – Exemplos de PTDs com melhor PB para as abordagens *AB 12* e *AB 14*, no cenário da MEDIANET.

CAPEX de 5072,267 u.m., Consumo energéticos de 335294,487 KM e conectividade algébrica de 0,376. Ou seja, um PTD com a probabilidade de bloqueio menor e, ainda assim, um PTD mais barato que o da abordagem *AB 14*.

A MEDIANET, inclusive, é uma rede com um nível de dificuldade para otimizar desafiador porque as distâncias entre os nós terminais são pequenas. A rápida resposta da abordagem *AB 12* MEDIANET, mostrou a robustez da técnica.

7 Discussão

Neste capítulo será discutido os resultados obtidos nos experimentos desta pesquisa, os resultados obtidos com as abordagens propostas serão comparados com o objetivo geral e com os objetivos específicos, também serão discutidos os motivos que fizeram uma abordagem ser melhor que a outra. O capítulo será dividido em seções onde primeiro será discutido o objetivo geral e depois os objetivos específicos. Por fim, será apresentado uma consideração geral em uma discussão final sobre questões específicas que geraram vantagens de uma abordagem sobre a outra.

7.1 Discussão sobre o objetivo geral

Para alcançar o objetivo geral foram usadas diferentes combinações de regra do *pivot*. Como mostram os experimentos aqui tratados, as diferentes combinações de regra do *pivot* geram resultados sensivelmente diferentes. Por isso, talvez a combinação dessas regras por si só já poderia ser um problema de otimização em estudos futuros, semelhante a *tuning* de parametrização de EAs (SIPPER et al., 2018). Todavia, o espectro de experimentos aqui realizados concluiu positivamente o objetivo geral dessa pesquisa visto que algumas regras do *Pivot* propostas alcançaram resultados superiores a propostas anteriores sem ter impacto no custo computacional final. No Capítulo 6, foram apresentados resultados de experimentos das várias abordagens estudadas, essas abordagens foram nomeadas para diferenciá-las indicando regras do *pivot* diferentes.

Muitas dessas regras do *pivot*, entretanto, não se mostraram promissoras, algumas até se mostraram quase que neutras em relação a uma execução sem aplicação de uma busca local, gerando assim uma série de abordagens equivalentes e outras até prejudiciais à evolução do EA. Ou seja, a versão memética do algoritmo não surtiu efeito sobre a evolução da população se comparada a uma abordagem não memética por causa da aplicação da busca local de forma sutil para evitar altos impactos no custo computacional. Ou então, a versão memética do algoritmo não surtiu efeito sobre a evolução da população por causa do uso de alguma estratégia de aplicação da busca local que se mostrou ruim por privilegiar *Exploitation* quando o mais importante, na situação, seria *exploration*. Porém, algumas regras do *pivot* reproduziram resultados positivos nos experimentos iniciais e mantiveram

esse aspecto positivos nos experimentos de ratificação, onde o número de execuções foi aumentado para investigar a estabilidade do comportamento.

Das abordagens estudadas, todas mantiveram exatamente 228000 avaliações de aptidão por execução do EA, esse número de avaliações é o mesmo número que o EA faria se não houvesse abordagem memética e o EA fosse configurado com os parâmetros de configuração da Tabela 3 e a Tabela 4 trocando o número de avaliação de aptidão para número de iteração igual a 500 (NASCIMENTO et al., 2018; FIGUEIREDO et al., 2016). Mesmo assim, algumas abordagens conseguiram alcançar resultados significativos mesmo mantendo o número de avaliações de aptidão inalterado. As que conseguiram foram: das abordagens de seleção de indivíduos aleatória, a abordagem *AB 6* que selecionou 8 indivíduos por iteração para aplicação da busca local, explorou a vizinhança de forma exaustiva Expl3 a partir da iteração 20, e das abordagens de seleção de indivíduos raros as abordagens *AB 9*, *AB 11* e *AB 12* que selecionaram 8 indivíduos por iteração para aplicação da busca local e explorou a vizinhança de forma exaustiva Expl3 a partir da iteração 20.

Contudo, o destaque foi para *AB 12* que aplicou a BLVMD com exploração da vizinhança de forma exaustiva adicionada da BLBIR, a busca local que não tem custo adicional relativo a uma nova avaliação de aptidão, e por isso, pode ser associada a outra busca local sem causar custo computacional excessivo. Essas duas abordagens combinaram perfeitamente, e por isso, foram escolhidas para que fossem associadas por 2 motivos.

1. As abordagens *AB 9* e *AB 11* que antecederam a *AB 12* por si só já apresentaram bons resultados, o que justificou o investimento em executar novos experimentos em uma abordagem que era uma evolução delas.
2. A área de localização estimada na curva de Pareto de investimento em melhorias da população realizada pela BLVMD nas abordagens que antecederam a *AB 12* eram exatamente a área de atuação da BLBIR, o que dá a possibilidade da BLBIR exportar as melhorias das investidas de sucesso da BLVMD para gerações futuras, enquanto investe em melhorar a distribuição da população.

Dessa forma as abordagens *AB 9*, *AB 11* e *AB 12*, com destaque para a *AB 12*, atingiram o objetivo geral da pesquisa apresentando um método para uso da busca local que melhore a qualidade das soluções oferecidas pelos métodos atuais sem aumentar o custo computacional geral da execução do algoritmo relativo ao número de avaliações

de aptidão no PTD. De forma mais singela, a *AB 6*, também conseguiu apresentar um método que atinge o objetivo geral da pesquisa.

7.2 Discussão sobre os objetivos específicos

Como resultado da investigação do problema para satisfazer o objetivo geral, vários objetivos específicos surgiram. Um deles foi uma investigação do comportamento da população a fim de encontrar algo que justifique o uso de uma busca local de forma que se apresente vantagem, a concepção do conceito de indivíduo raro é fruto dessa investigação. O conceito de indivíduo raro foi construído observando o hiperplano normatizado em tempo de execução na seleção de sobreviventes, as características de cada indivíduo na população é o que o torna apto a ser selecionado ou não para uma geração futura, foi observado áreas entre as dimensões do hiperplano normatizado onde soluções não sobreviviam porque simplesmente não existiam. O conceito de indivíduo raro e o aspecto de tirar vantagem do conceito, em si, para aplicação de uma busca local é uma das contribuições desse trabalho.

Uma outra contribuição foi a BLVMD que diferente da busca proposta em Nascimento *et al.*, a BLVMD proposta aqui faz modificações que influenciam os 4 objetivos do algoritmo, inclusive, fazendo uma busca mais apurada no espaço de busca referente ao objetivo de CA. Dessa forma a BLVMD é uma nova busca local oriunda de uma melhoria na busca local de (NASCIMENTO *et al.*, 2018), que faz modificações apenas em três dos quatro objetivos do problema (NASCIMENTO *et al.*, 2020).

Por ter possibilidade de inspirar vários estudos futuros, a BLBIR posposta aqui talvez seja a proposta mais promissora desta pesquisa. A BLBIR não visualiza como solução um indivíduo em si em meio a população, para a BLBIR uma solução é uma população com uma quantidade pequena de indivíduos classificados como raros, e uma solução vizinha boa é uma população com uma quantidade maior desses indivíduos que foram classificados como raros. Portanto, a BLBIR não manipula um indivíduo em si e sim uma parte da população dando prioridade na lista de pais a indivíduos melhorados por outras buscas locais, assim como a indivíduos considerados como raros no momento da atuação. Dessa forma, a BLBIR aproveita a avaliação de aptidão normal do fluxo do EA, não precisando de uma nova avaliação de aptidão sempre que ela é usada, sendo uma busca local sem custo adicional de uma nova avaliação de aptidão.

A BLBIR também tem a possibilidade de ser experimentada em outros problemas parecidos com o PTD, todavia, o objetivo geral desse trabalho foi focado em usar uma busca local economizando custo computacional para propor uma abordagem rápida mesmo com o uso da busca local, portanto, não faria sentido escolher um problema que não fosse custoso ou não seria possível experimentar o ganho em tempo. Por questões de delimitação de escopo, a BLBIR não foi experimentada em mais de um problema combinatório, entretanto, pode-se afirmar com segurança que a BLBIR não observa aspectos específico, exclusivamente, do PTD e sim a distribuição de uma população de forma geral. Não é possível afirmar que a BLBIR seja bem adaptável a outros problemas combinatórios parecidos com o PTD antes de experimentá-la em outros problemas, contudo, esse aspecto geral da BLBIR de não observar questões específicas exclusivamente do PTD, e sim questões específicas do tipo de problema parecido com o PTD em um EA, que é a distribuição, torna a BLBIR uma busca local que tem o potencial muito forte em ser promissora em outros problemas combinatórios.

Outra contribuição importante se refere a quando a abordagem não permite a aplicação da busca local na população inteira por questões de custo computacional. A abordagem de seleção de $z\%$ de indivíduos na população entre os indivíduos raros, Seção 4.3 - forma de observação simples da Definição 1 relaxada, descreve uma forma de executar a seleção dos indivíduos em meio a população para aplicação de uma busca local. A seleção de $z\%$ da população apresenta vantagens para a seleção de indivíduos raros como mostra a *AB 9*, *AB 11* e *AB 12*, no Capítulo 6. A abordagem de seleção de indivíduos raros inclusive, ofereceu uma solução para a questão do Pareto único, Seção 4.2, observando a distribuição da população e tirando proveito desse aspecto.

Os resultados dos experimentos desta pesquisa, respondem positivamente as perguntas da pesquisa:

- **Resposta para a pergunta de pesquisa 1:** Sim, é possível !
 - Mesmo fixando o custo computacional em termos de avaliação de aptidão na Figura 30, logo no terceiro de 25 marcos de avaliação de aptidão, a abordagem *AB 12* mostra um exemplo de superação de uma abordagem anterior encontrado valores de HV nunca encontrados pela abordagem de um estudo anterior.
- **Resposta para a pergunta de pesquisa 2:** Sim, é possível!
 - Com um custo computacional menor, uma das abordagens mostrada na Figura

33, logo no segundo de 25 marcos de avaliação de aptidão a abordagem *AB* 12 aplicada ao estudo de caso da MEDIANET, encontra valores de HV nunca encontrados pela abordagem de um estudo anterior.

7.3 Discussão final

Como demonstrado nos resultados expostos no Capítulo 6 e nas argumentações das Seções 7.1 e 7.2, as abordagens com diferentes regras do *pivot* conseguiram alcançar os objetivos da pesquisa, contudo, alguns aspectos precisam ser melhor explicados.

É necessário explicar por que a abordagem que explora a vizinhança até encontrar uma solução dominante e para Expl2, se mostrou em termos estatísticos tão ruim, se uma abordagem parecida Expl3 que explora a vizinhança até a exaustão se mostrou promissora. É importante observar que se mostrar estatisticamente ruim não significa que todas as execuções de uma abordagem sejam incapazes de produzir resultados bons, todavia, em termos estatísticos, no *tradeoff* as execuções ruins acabam anulando as boas. O problema que foi observado na Expl2, nos experimentos dessa pesquisa, é que a exploração excessiva da vizinhança em busca de refinamento acaba causando um efeito em cascata que prejudica a evolução, mesmo a Expl2 sendo aplicada em poucos indivíduos.

Quando a Expl2 deixa de achar soluções bem melhores através de *exploration* em busca de *exploitation*, deixa também de conseguir diversificar a população, além de incorrer em risco de prisão em máximos locais (LINDEN, 2008). Já a Expl3, pela forma que o problema foi implementado, tirou vantagem da exploração da vizinhança inteira.

Essa vantagem é em função da lista de cidades vizinhas que é ordenada: a primeira posição da lista é a cidade mais próxima da cidade que detém o POP, enquanto a última posição da lista é a cidade mais distante da cidade detentora do POP das n cidades selecionadas como vizinhança. Esse aspecto não é relevante quando a seleção da solução vizinha é por sorteio Expl1, (NASCIMENTO et al., 2018). Todavia, da maneira que foi implementado neste estudo a busca local explora a lista de cidades vizinhas do início para o fim, portanto no caso da Expl3, principalmente quando há duas soluções ou mais na vizinhança que ofereça dominação, o que acaba acontecendo é que ocorre *exploitation* quando a busca local encontra apenas uma solução dominante e logo nas primeiras posições da lista, por outro lado, há uma simulação de *exploration* quando a busca local encontra

mais de uma solução dominante.

A Figura 36 mostra uma ilustração da simulação de exploração executada pela Expl3.

Fonte: o autor.




Figura 36 – Simulação de *exploration* pela realizado pela exploração da vizinhança Expl3.

Na Figura 36A, o triângulo é a cidade que detém o POP, os círculos rotulados de *d1* e *d2* são as cidades vizinhas que têm o potencial para ser dominante, os quadrados são as cidades que também são vizinhas, mas, que não têm potencial para ser dominante, o losango é uma outra cidade qualquer dentro do grupo, mas, que não foi marcada como cidade vizinha. Na Figura 36A, o número de vizinhos considerados mais próximos são 5.

Supondo que na Figura 36 irá ser aplicada uma abordagem de busca local que examine a vizinhança por exaustão Expl3. Na situação inicial, Figura 36A, nada ainda ocorreu e o PTD ainda está em seu estado original. Depois de duas aplicações da busca local que não foram bem-sucedidas, há uma terceira aplicação da busca e essa sim obtém sucesso. Então, a situação fica como no estado 2, Figura 36B, onde o POP foi mudado de posição pela busca local para a terceira cidade vizinha mais próxima, a *d1*. Além disso, um enlace novo foi adicionado pela busca local entre os POPs do grupo 2 e o grupo 4. No estado 2, o algoritmo constatou que a nova solução era dominante e a solução original foi

substituída pela nova na população.

Após o estabelecimento do estado 2, a busca local continua examinando a vizinhança em busca de uma segunda solução que domine a solução encontrada no estado 2. Após a quinta investida da busca local, o algoritmo chega no estado 3, Figura 36C, nesse ponto o POP foi mudado de posição pela busca local para a cidade onde antes estava marcada como cidade com potencial dominante $d2$ e um novo enlace foi criado entre os POPs do grupo 1 e o grupo 4. Então, o algoritmo verifica a nova dominação e substitui a solução na população, a exploração da vizinhança chega à exaustão e as execuções da busca local param.

Acontece que, como descreve a Subseção 3.3.4, um vizinho para uma solução alterada por uma busca local é por definição uma solução próxima a solução original, ou seja, literalmente uma solução refinamento da solução original. É razoável considerar que usando como exemplo o ambiente de implantação do PTD como o estado de Pernambuco, após 5 deslocamentos de posição a nova posição do POP esteja com pelo menos 60 km de distância da posição original. Além disso, o PTD vai estar com dois enlaces a mais, ou seja, o novo PTD que deveria ser um PTD que se traduzisse em uma solução vizinha, tem dois enlaces a mais e tem um de seus POPs com pelo menos 60 km de distância da solução original, portanto, o novo PTD não pode mais ser considerado uma topologia vizinha.

Resumindo, a Expl3 executaria *exploitation* se obtivesse sucesso apenas no estado 2, Figura 36B. Todavia, se o sucesso também estiver no estado 3, Figura 36C, A Expl3 simula *Exploration*. Em um cenário assim, a exploração Expl1 não se prejudicaria porque ela sortearia um dos vizinhos e sendo uma investida de sucesso ou não, a Expl1 não continuaria a exploração, causando um número muito baixo de avaliações de aptidão extras. Já a exploração Expl2 usaria 3 avaliações de aptidão extra e pararia no estado 2, Figura 36B, usando quase tantas avaliações de aptidão quanto a Expl3, porém, sem aproveitar as vantagens que a exploração exaustiva da vizinhança pode oferecer.

8 Conclusão

Esta pesquisa propôs uma abordagem para otimização de projetos de redes ópticas WDM com foco em algoritmos evolucionários meméticos multiobjetivo. A modelagem do problema considerou adicionalmente a localização dos nós terminais como variável de decisão e otimizou 4 objetivos conflitantes: PB, CAPEX, consumo energético e robustez. A principal contribuição da dissertação foi propor um algoritmo evolucionário combinado com busca local que supera as abordagens já propostas na literatura.

As regras do *pivot* tratadas nesse estudo foram capazes de responder positivamente às perguntas da pesquisa levantadas inicialmente e os conceitos inovativos dos quais os experimentos mostraram sucesso são inspiradores. Pelo menos para o problema tratado por esta pesquisa, existem maneiras de alcançar os ganhos que uma busca local proporciona a um PTD, sem que haja aumento de custo computacional relativos a avaliações de aptidão extras causados pelo uso da busca local. Vários experimentos foram conduzidos com todas as configurações listadas na Tabela 6, além dos experimentos extras. Só desses experimentos mais de 850 execuções foram realizadas e isso de um problema onde a maioria das execuções duram no mínimo entre 24 e 48 horas, mas, que não raramente duram até uma semana para produzir um ponto no gráfico de resultados.

A principal abordagem desta dissertação apresentou resultados até 7,92% melhores em termos de HV quando comparada com o estado da arte no mesmo problema (NASCIMENTO et al., 2020). Todavia, as possibilidades de combinações de estratégia para montagem de uma abordagem que se traduza em um modo de exploração de vizinhança de solução através de uma busca local, mais conhecida como regras do *pivot* em um EA, não são tão facilmente exauridas. Há uma infinidade de outras abordagens que, por uma questão de escopo, não foram experimentadas. A conclusão deste trabalho irá listar primeiramente os pontos francos e depois fará uma sugestão para trabalhos futuros, para no fim realizar as considerações finais desta obra.

Algumas das limitações já identificadas neste trabalho incluem: não avaliar a BLBIR em outros problemas combinatórios, devido à limitação de escopo; não ter como afirmar que a Expl3 se mostre eficiente em outros problemas parecidos com o PTD, existe a possibilidade de a Expl3 ter se mostrado promissora apenas por causa das características do PTD, causando o efeito de por um lado refinar e por outro explorar discutido na Seção

7.3; Não ter combinado a BLBIR com a Expl2, no estudo publicado em (NASCIMENTO et al., 2020) foi usado a BLBIR combinada com a exploração da vizinhança Expl1, mas, nenhum estudo que combinasse a Expl2 com a BLBIR foi conduzido; Não ter realizado nenhum estudo de otimização para configuração das regras do *pivot*, como uma espécie de *tuning* de parametrização de EAs (SIPPER et al., 2018); Não ter experimentado a BLBIR com outras buscas locais além da BLVMD. As sugestões de trabalhos futuros na próxima subseção consideram algumas destas limitações e fornecem um possível direcionamento para continuação desta pesquisa.

8.1 Trabalhos futuros

E com os desdobramentos dos conceitos experimentados e resultados obtidos nessa dissertação, trabalhos futuros podem conduzir a seguinte linha de pesquisa.

1. Experimentar a BLBIR em outros problemas combinatórios.
2. Um estudo que classifique execuções em andamento como promissoras ou não e aponte o uso de algum indicador existente, ou, que crie um indicador para apontar esse aspecto, além da estratégia para correção do problema em tempo de execução.
3. Exploração dos indivíduos raros da maneira detalhada, como explicada na Definição 1 da Seção 4.3.
4. Nas observações do funcionamento do hiperplano normatizado implementando pelo Jmetal (NEBRO et al., 2015), foi observado que muitos dos pontos de referência ficam sem nenhuma solução (DEB; JAIN, 2013). Esses pontos têm localização exata, conduzir uma investigação sobre uma evolução da BLBIR que possa tirar proveito desse aspecto da localização exata.
5. Um estudo usando indicadores de distribuição e convergência separadamente, para levantar maiores detalhes sobre as vantagens que as abordagens tratadas nestes trabalho alcançaram.
6. Traçar uma estratégia para uma busca local que, de forma tradicional modifique um indivíduo da população, estratégia essa, para que a busca local aproveite a avaliação de aptidão normal do EA para avaliar a solução modificada.
7. Colocar um parâmetro de controle sobre o tamanho da fatia da população dos pais que a BLBIR pode preencher.

8. A variância entre as porcentagens dos tipos de indivíduos, na população, foi definida como 0,01 de forma empírica, todavia, a grandeza foi definida como um parâmetro de entrada. Uma investigação de vários valores desse parâmetro traduziria o quanto o parâmetro pode influenciar os resultados do EA.
9. Experimentar a BLBIR em outros algoritmos que façam uso do hiperplano normatizado.
10. Investigar o uso de uma função de aptidão inserida em um sistema distribuído de forma que, minimize a minutos, o tempo de execução total do algoritmo.
11. A medida matemática que a equalização da quantidade dos tipos de indivíduos na população se baseou, nesse estudo, foi a média da população. Uma investigação sobre a possibilidade de outras medidas matemáticas surtirem mais efeitos pode dar maiores detalhes sobre a natureza da equalização dos tipos de indivíduos na população.
12. Experimentar o casamento dos conceitos experimentados aqui com os do trabalho publicado em ([ABOUHAWWASH et al., 2017](#)), que usa outra estratégia de seleção de indivíduos, em meio a população, para aplicação da busca local. Vale ressaltar que o autor de ([ABOUHAWWASH et al., 2017](#)) deixa claro que a técnica usada, em seu trabalho, apresentou dificuldades com distribuição.

Por fim, este estudo chega à conclusão final de que a busca local é um procedimento que vale a pena ser usado pela qualidade das soluções que ela proporciona, todavia, não vale a pena gastar muito esforço com refinamento quando a prioridade tem que ser exploração. Existe momento certo tanto para exploração quanto para refinamento. É preciso existir uma abordagem que dose o uso dos dois seguimentos de descobertas de novas soluções *exploitation* e *exploration*. Esse trabalho também chega à conclusão de que é possível usar estratégias que somatizem o exato custo total final, relativos a avaliações de aptidão, que o algoritmo teria se não usasse uma abordagem memética e mesmo assim fazer uso da busca local.

8.1.1 Publicações Relacionadas

A condução desta pesquisa gerou os seguintes trabalhos:

1. NASCIMENTO, J. C.; ARAÚJO, D. R. B.; MIRANDA, P. B. C. A Novel Strategy

for Selecting Individuals in Manyobjective Algorithms with Local Search Applied to the Network Design Problem In: 16h Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2020, Rio Grande.

2. NASCIMENTO, J. C.; ARAÚJO, D. R. B.; MIRANDA, P. B. C.A. A Memetic Manyobjective Evolutionary Algorithm for Design Optical Networks. Expert systems with applications, 2021 (em preparação)

Referências

- ABOUHAWWASH, M.; SEADA, H.; DEB, K. Towards faster convergence of evolutionary multi-criterion optimization algorithms using karush kuhn tucker optimality based local search. **Computers & Operations Research**, Elsevier, v. 79, p. 331–346, 2017.
- ALVES, M. J.; ALMEIDA, M. Motga: A multiobjective tchebycheff based genetic algorithm for the multidimensional knapsack problem. **Computers & operations research**, Elsevier, v. 34, n. 11, p. 3458–3470, 2007.
- 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), 2015.
- ARAÚJO, D. R. de; BASTOS-FILHO, C. J.; MARTINS-FILHO, J. F. Métricas de redes complexas para análise de redes ópticas. **Revista de Tecnologia da Informacao e Comunicacao**, v. 4, n. 2, p. 11–18, 2014.
- AZODOLMOLKY, S.; PERELLÓ, J.; ANGELOU, M.; AGRAZ, F.; VELASCO, L.; SPADARO, S.; POINTURIER, Y.; FRANCESCON, A.; SARADHI, C. V.; KOKKINOS, P. et al. Experimental demonstration of an impairment aware network planning and operation tool for transparent/translucent optical networks. **Journal of Lightwave Technology**, IEEE, v. 29, n. 4, p. 439–448, 2010.
- BARBOSA, F.; SOUSA, A. de; AGRA, A. Topology design of transparent optical networks resilient to multiple node failures. In: IEEE. **2018 10th International Workshop on Resilient Networks Design and Modeling (RNDM)**. [S.l.], 2018. p. 1–8.
- CASTRO-GUTIERREZ, J.; LANDA-SILVA, D.; PÉREZ, J. M. Nature of real-world multi-objective vehicle routing with evolutionary algorithms. In: IEEE. **2011 IEEE International Conference on Systems, Man, and Cybernetics**. [S.l.], 2011. p. 257–264.
- CHATTERJEE, B. C.; BA, S.; OKI, E. Fragmentation problems and management approaches in elastic optical networks: a survey. **IEEE Communications Surveys & Tutorials**, IEEE, v. 20, n. 1, p. 183–210, 2017.
- CHAVES, D. A.; BASTOS-FILHO, C. J.; MARTINS-FILHO, J. F. Multiobjective physical topology design of all-optical networks considering qos and capex. In: OPTICAL SOCIETY OF AMERICA. **Optical Fiber Communication Conference**. [S.l.], 2010. p. JThA45.
- 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.
- CHAVES, D. A. R. **Projeto de redes ópticas de alta capacidade utilizando técnicas de otimização bioinspiradas**. Tese (Doutorado), 2012.

CIRIACO, D. **A história da conexão**. 2009. Accessed: 28-04-2021. Disponível em: <https://www.tecmundo.com.br/banda-larga/2543-a-historia-da-conexao.htm>.

CORMEN, T. H.; LEISERSON, C. E.; RIVEST, R. L.; STEIN, C. **Introduction to algorithms**. [S.l.]: MIT press, 2009.

CUZICK, J. A wilcoxon-type test for trend. **Statistics in medicine**, Wiley Online Library, v. 4, n. 1, p. 87–90, 1985.

DAS, I.; DENNIS, J. E. Normal-boundary intersection: A new method for generating the pareto surface in nonlinear multicriteria optimization problems. **SIAM journal on optimization**, SIAM, v. 8, n. 3, p. 631–657, 1998.

DEB, K.; JAIN, H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: solving problems with box constraints. **IEEE transactions on evolutionary computation**, IEEE, v. 18, n. 4, p. 577–601, 2013.

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.

DUPLEIX, V.; ARAÚJO, D. R.; BASTOS-FILHO, C. J. Multiobjective evolutionary approach to design the transport infrastructure from haiti. In: **Proceedings of the 2016 IEEE LA-CCI**. [S.l.: s.n.], 2016. p. 1–6.

DURAN, R.; FERNANDEZ, N.; MIGUEL, I. de; ANGELOU, M.; SÁNCHEZ, D.; AGUADO, J.; JIMÉNEZ, T.; FERNANDEZ, P.; MERAYO, N.; ATALLAH, N. et al. Advantages of using cognition when solving impairment-aware virtual topology design problems. In: IEEE. **2011 13th International Conference on Transparent Optical Networks**. [S.l.], 2011. p. 1–4.

DUTTA, J.; DEB, K.; TULSHYAN, R.; ARORA, R. Approximate kkt points and a proximity measure for termination. **Journal of Global Optimization**, Springer, v. 56, n. 4, p. 1463–1499, 2013.

EIBEN, A. E.; SMIT, S. K. Evolutionary algorithm parameters and methods to tune them. In: **Autonomous search**. [S.l.]: Springer, 2011. p. 15–36.

_____. Parameter tuning for configuring and analyzing evolutionary algorithms. **Swarm and Evolutionary Computation**, Elsevier, v. 1, n. 1, p. 19–31, 2011.

EIBEN, A. E.; SMITH, J. E. et al. **Introduction to evolutionary computing**. [S.l.]: Springer, 2003. v. 53.

FAGERLAND, M. W.; SANDVIK, L. The wilcoxon–mann–whitney test under scrutiny. **Statistics in medicine**, Wiley Online Library, v. 28, n. 10, p. 1487–1497, 2009.

FIGUEIREDO, E. M.; ARAÚJO, D. R.; BASTOS-FILHO, C. J.; LUDERMIR, T. B. Physical topology design of optical networks aided by many-objective optimization algorithms. In: IEEE. **2016 5th Brazilian Conference on Intelligent Systems (BRACIS)**. [S.l.], 2016. p. 409–414.

GROUP, T. K. **Speed Amp RAMAN**. 2020. Accessed: 19-01-2021. Disponível em: <<https://www.thekentongroup.com/products/opticalandfibreproducts/wdmsystems/pandacomspedots5000series/amplifiers/speedampraman/#tab1>>.

HEDDEGHEM, W. V.; IDZIKOWSKI, F.; VEREECKEN, W.; COLLE, D.; PICKAVET, M.; DEMEESTER, P. Power consumption modeling in optical multilayer networks. **Photonic Network Communications**, Springer, v. 24, n. 2, p. 86–102, 2012.

HERON, R. W.; PFEIFFER, T.; VEEN, D. T. v.; SMITH, J.; PATEL, S. S. Technology innovations and architecture solutions for the next-generation optical access network. **Bell Labs Technical Journal**, Wiley Online Library, v. 13, n. 1, p. 163–181, 2008.

ISHIBUCHI, H.; MURATA, T. A multi-objective genetic local search algorithm and its application to flowshop scheduling. **IEEE transactions on systems, man, and cybernetics, part C (applications and reviews)**, IEEE, v. 28, n. 3, p. 392–403, 1998.

JEBARI, K.; MADIAFI, M. Selection methods for genetic algorithms. **International Journal of Emerging Sciences**, Springfield Publishing Corporation, v. 3, n. 4, p. 333–344, 2013.

KE, L.; ZHANG, Q.; BATTITI, R. A simple yet efficient multiobjective combinatorial optimization method using decomposition and pareto local search. **IEEE Trans on Cybernetics**, accepted, 2014.

KLEINA, N. **Entramos no Bate-Papo da UOL em 2017 para saber o que ainda acontece por lá**. 2017. Accessed: 28-04-2021. Disponível em: <<https://www.tecmundo.com.br/brasil/118052-entramos-bate-papo-uol-2017-saber-ainda-acontece.htm>>.

KNOWLES, J. D.; THIELE, L.; ZITZLER, E. A tutorial on the performance assessment of stochastic multiobjective optimizers. **TIK-Report**, ETH Zurich, v. 214, 2006.

LIMA, N. J. d. S.; BASTOS-FILHO, C. J.; ARAÚJO, D. R. Boolean operators to improve multi-objective evolutionary algorithms for designing optical networks. **Journal of Microwaves, Optoelectronics and Electromagnetic Applications**, SciELO Brasil, v. 15, n. 4, p. 319–332, 2016.

LIMA, R. **Pandemia do coronavírus já causa lentidão na internet pelo mundo**. TecMundo, 2021. Accessed: 28-04-2021. Disponível em: <<https://www.tecmundo.com.br/internet/151213-pandemia-coronavirus-causa-lentidao-internet-mundo.htm>>.

LINDEN, R. **Algoritmos genéticos (2a edição)**. [S.l.]: Brasport, 2008.

LOOS, P. **Como Seria Viver em 4 Dimensões?** 2019. Disponível em: <<https://www.youtube.com/watch?v=iY9eA7-WY54#t=6m45s>>.

LUST, T.; TEGHEM, J. The multiobjective multidimensional knapsack problem: a survey and a new approach. **International Transactions in Operational Research**, Wiley Online Library, v. 19, n. 4, p. 495–520, 2012.

MANSOUR, I. B.; ALAYA, I.; TAGINA, M. Chebyshev-based iterated local search for multi-objective optimization. In: IEEE. **2017 13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)**. [S.l.], 2017. p. 163–170.

NASCIMENTO, J.; ARAÚJO, D.; MIRANDA, P. Uma nova estratégia para seleção de indivíduos em algoritmos multiobjetivos com busca local aplicados ao problema de projeto de redes. In: SBC. **Anais do XVII Encontro Nacional de Inteligência Artificial e Computacional**. [S.l.], 2020. p. 164–175.

NASCIMENTO, J. C.; ARAUJO, D. R.; BASTOS-FILHO, C. J.; MARTINS-FILHO, J. F. Manyobjective optimization to design physical topology of optical networks with undefined node locations. In: IEEE. **2018 IEEE Congress on Evolutionary Computation (CEC)**. [S.l.], 2018. p. 1–7.

NASCIMENTO, J. C. d. **Projeto integrado de redes ópticas de longa distância e Metropolitanas usando algoritmos de inteligência computacional: estudo de caso para o estado de Pernambuco**. Dissertação (B.S. thesis) — Brasil, 2017.

NEBRO, A. J.; DURILLO, J. J.; VERGNE, M. Redesigning the jmetal multi-objective optimization framework. In: **Proceedings of the companion publication of the 2015 annual conference on genetic and evolutionary computation**. [S.l.: s.n.], 2015. p. 1093–1100.

RAMASWAMI, R.; SIVARAJAN, K.; SASAKI, G. **Optical networks: a practical perspective**. [S.l.]: Morgan Kaufmann, 2009.

REGIÃO, S. d. T. d. I. Tribunal Regional Federal da **JFPE - Seção / Subseções**. 2020. Accessed: 19-01-2021. Disponível em: <<https://www.jfpe.jus.br/index.php/institucional/secao-subsecoes.html>>.

SCHEIFER, V. **Tráfego da internet brasileira na pandemia: quais foram os impactos?** 2021. Accessed: 28-04-2021. Disponível em: <<https://www.tecmundo.com.br/internet/154628-trafego-internet-brasileira-pandemia-impactos.htm>>.

SIPPER, M.; FU, W.; AHUJA, K.; MOORE, J. H. Investigating the parameter space of evolutionary algorithms. **BioData mining**, Springer, v. 11, n. 1, p. 1–14, 2018.

TESSINARI, R. S.; PAIVA, M. H.; MONTEIRO, M. E.; SEGATTO, M. E.; GARCIA, A. S.; KANELLOS, G. T.; NEJABATI, R.; SIMEONIDOU, D. On the impact of the physical topology on the optical network performance. In: IEEE. **2018 IEEE British and Irish Conference on Optics and Photonics (BICOP)**. [S.l.], 2018. p. 1–4.

TRONCO, T. R.; AVILA, L. F. de. Fundamentos de comunicações ópticas. **1a Edição: Abril de**, 2007.

WIEDERHOLD, B. K. **Connecting through technology during the coronavirus disease 2019 pandemic: Avoiding “Zoom Fatigue”**. [S.l.]: Mary Ann Liebert, Inc., publishers 140 Huguenot Street, 3rd Floor New ... , 2020.

ZHANG, Q.; LI, H. Moea/d: A multiobjective evolutionary algorithm based on decomposition. **IEEE Transactions on evolutionary computation**, IEEE, v. 11, n. 6, p. 712–731, 2007.

ZHOU, Y.; WANG, J. A local search-based multiobjective optimization algorithm for multiobjective vehicle routing problem with time windows. **IEEE Systems Journal**, IEEE, v. 9, n. 3, p. 1100–1113, 2014.

ZITZLER, E.; LAUMANN, M.; THIELE, L. Spea2: Improving the strength pareto evolutionary algorithm. **TIK-report**, Eidgenössische Technische Hochschule Zürich (ETH), Institut für Technische ..., v. 103, 2001.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. **IEEE transactions on Evolutionary Computation**, IEEE, v. 3, n. 4, p. 257–271, 1999.