



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS

Programa de Mestrado em Engenharia de Produção e Sistemas

**Otimização de Redes de Fibra Óptica usando Algoritmos de
Busca Discreta Cuco Híbridos com Algoritmo Genético**

RAYANE ARAÚJO LIMA

março de 2022

Otimização de Redes de Fibra Óptica usando Algoritmos de Busca Discreta Cuco Híbridos com Algoritmo Genético

RAYANE ARAÚJO LIMA

Dissertação de Mestrado apresentada ao Programa de Pos-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Prof^o. Marcos Lajovic Carneiro, Dr.

Goiânia-Go,
março de 2022

Catálogo na Fonte - Sistema de Bibliotecas da Pontifícia Universidade Católica de Goiás
Márcia Rita Freire - Bibliotecária - CRB1/1551

L732o Lima, Rayane Araujo
Otimização de redes de fibra óptica usando algoritmos
de busca discreta cuco híbridos com algoritmo genético
/ Rayane Araujo Lima. -- 2022.
68 f.: il.

Texto em português, com resumo em inglês
Dissertação (mestrado) -- Pontifícia Universidade
Católica de Goiás, Escola Politécnica, Goiânia, 2022

Inclui referências: f. 63-68.

1. Algoritmos. 2. Otimização combinatória. 3. Comunicações
ópticas. I. Carneiro, Marcos Lajovic. II. Pontifícia Universidade
Católica de Goiás - Programa de Pós-Graduação em Engenharia
de Produção e Sistemas - 17/03/2022. III. Título.

CDU: Ed. 2007 -- 004.722(043)
621.3.011.75

Otimização de Redes de Fibra Óptica usando Algoritmos de Busca Discreta Cuco Híbridos com Algoritmo Genético

Rayane Araújo Lima

Esta Dissertação foi julgada adequada para obtenção do título de Mestre em Engenharia de Produção e Sistemas, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás em março de 2022.



Prof. Marcos Lajovic Carneiro, *Dr.*
Coordenador do Programa de
Pós-Graduação
em Engenharia de Produção e Sistemas

Banca Examinadora:



Prof^o. Marcos Lajovic Carneiro, *Dr.*
Orientador



Prof^a. Maria José Pereira Dantas, *Dra.*
PUC-Goiás



Prof. Flávio Henrique Teles Vieira, *Dr.*
Universidade Federal de Goiás

Goiânia-Go
março de 2022

Dedico esse trabalho a minha mãe, Maria de Deus Araújo Lima (Deusa) e meu amigo e irmão Kaique !

AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus, que foi minha fonte de forças em toda a caminhada. Agradecer minha mãe Deusa Araújo Lima, que sempre me apoiou em todas as decisões e nunca me desamparou, ao meu melhor amigo Kaique Soares, que teve função fundamental em toda a minha vida acadêmica, que sempre me aconselhou a nunca desistir, mesmo quando tudo parecia impossível.

Agradeço ao meu AVÔ (eterno Paiéi) e a minha AVÓ que vieram a falecer no meio do meu Mestrado, mas que mesmo não estando presentes fisicamente pude sentir de certa forma que vocês estavam ao meu lado em todos os momentos em que precisei, e jamais esquecerei quando minha Avó disse que iria se matricular na faculdade só para me ver dando aula, mesmo ela nem sabendo ler e escrever, a sua simplicidade me fez muito feliz.

Ao Prof. Dr. Bruno Quirino de Oliveira e ao Prof. Dr. Marcos Lajovic Carneiro pela cooperação ao trabalho de pesquisa.

Finalmente, gostaria de agradecer à CAPES e ao Programa de Pós-graduação em Engenharia de Produção e Sistemas da PUC-GO pelos apoios financeiros (fornecidos) durante a minha formação.

*...buscai, assim, em primeiro lugar o Reino de Deus e a sua justiça, e todas essas coisas
vos serão acrescentadas.*

(Bíblia sagrada, Matheus 6:33)

RESUMO

Resumo da Dissertação apresentada ao MEPROS/ PUC Goiás como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Produção e Sistemas (M.Sc.)

OTIMIZAÇÃO DE REDES DE FIBRA ÓPTICA USANDO ALGORITMOS DE BUSCA DISCRETA CUCO HÍBRIDOS COM ALGORITMO GENÉTICO

Rayane Araújo Lima

março de 2022

Orientador: Prof^o. Marcos Lajovic Carneiro, Dr.

RESUMO: O planejamento de uma rede óptica representa um dos mais desafiadores da indústria de telecomunicações. Sua natureza discreta e combinatória aborda problemas técnicos e econômicos, como a alocação de recursos e de enlaces e nós, a proteção de falhas, limitação orçamentárias, além de ser custoso para os projetistas e engenheiros, dentre outros. Neste trabalho são propostas algumas estratégias para projetar redes de transportes ópticas- multiplexação por comprimento de onda *Optical Transport Network - Wavelength Division Multiplexing (OTN/WDM)* de forma otimizada. A rede pode ser considerada como um grafo que possui tráfego de dados dinâmico a ser escoada pelos nós de origem até o destino. As estratégias propostas lidam com um dos principais elementos que afetam a relação custo desempenho de uma rede óptica: o projeto da topologia física da rede (PTD). Para o problema PTD são consideradas os custos de capital (CapEx) e operacional (OpEx) para análise do desempenho da rede. Dois modelos de algoritmos metaheurísticos são propostos, o primeiro usa uma adaptação do algoritmo busca cuco e o segundo utiliza o algoritmo busca cuco híbrido com o algoritmo genético. Neste sentido, esses modelos são utilizados para resolver o problema MILP, para o planejamento da rede de transporte óptica (OTN), considerando a minimização de custos. Restrições de garantia de atendimento de demanda, de especificidade de capacidade técnica de equipamentos e de exclusividade na alocação de modularidade de enlace de transmissão também são contempladas. Logo o objetivo é fornecer estratégias que possibilitem à tomada de decisão de forma eficiente e realista levando em consideração o cenário que possibilitem a aplicação que se pretende retratar. Os resultados computacionais encontrados são promissores, a otimização resultou em modelos de topologias com custos reduzidos, uma redução de até 11.05% para a rede de menor porte e até 3.34% para a rede de maior porte.

Palavras-chave: Problemas combinatoriais, Otimização de rede, Algoritmo Busca Cuco e Algoritmo Busca Cuco Híbrido.

ABSTRACT

Resumo da Dissertação apresentada ao MEPROS/ PUC Goiás como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Produção e Sistemas (M.Sc.)

OTIMIZAÇÃO DE REDES DE FIBRA ÓPTICA USANDO ALGORITMOS DE BUSCA DISCRETA CUCCO HÍBRIDOS COM ALGORITMO GENÉTICO

Rayane Araújo Lima

março de 2022

Advisor: Prof^o. Marcos Lajovic Carneiro, Dr.

Abstract: Planning an optical network represents one of the most challenging in the telecommunications industry. Its discrete and combinatorial nature presents technical and economic problems, such as the resources' allocation, links and nodes, protection from failures, budget limitations, in addition to being costly for designers and engineers, among others. This work proposes some strategies to optimally design OTN/WDM networks. The network can be considered as a graph that has dynamic data traffic to flow from the source nodes to the destination. The proposed strategies deal with one of the main elements that affect the cost-performance ratio of an optical network: the design of the physical network topology (PTD). For the PTD problem, capital (CapEx) and operational (OpEx) costs are considered for analysis of network performance. Two models of metaheuristic algorithms are proposed, the first uses an adaptation of the cuckoo search algorithm and the second uses the hybrid cuckoo search algorithm with the genetic algorithm. These models are used to solve the MILP problem, for the planning of the optical transport network (OTN), considering cost minimization. Restrictions on guaranteeing demand fulfillment, specificity of the equipment technical capacity and exclusivity in the allocation of transmission link modularity are also contemplated. Therefore, the goal is to provide strategies that enable decision-making efficiently and realistically, taking into account the application scenario that is intended to portray. The computational results found are promising, the optimization resulted in topology models with reduced costs and relatively low processing time for a large network.

Keywords: Optimization, Fiber Optic Network, Cuckoo Search Algorithm and Hybrid Cuckoo Search Algorithm.

LISTA DE ILUSTRAÇÕES

Figura 1 – Networking hierarchy based on geography. (SIMMONS, 2008).....	21
Figura 2 – OTN Hierarchy (JORGE, 2012).	23
Figura 3 – Representação das três camadas ópticas hierárquicas do OTN em execução (GILCHRIST, 2015).	24
Figura 4 – Grafo simples com três vértices e três arestas.	26
Figura 5 – Exemplos de caminhos para uma rede de três nós.	27
Figura 6 – Fluxo de controle do algoritmo evolutivo.	30
Figura 7 – <i>Crossover</i> ponto único.....	31
Figura 8 – <i>Crossover</i> de dois pontos.	31
Figura 9 – <i>Crossover</i> uniforme.	31
Figura 10 – Troca de posição de genes.....	32
Figura 11 – Distância de <i>Hamming</i> entre dois vetores.....	35
Figura 12 – Lacunas geradas pela distância de <i>Hamming</i>	36
Figura 13 – Lacunas preenchidas.	36
Figura 14 – Representação da Rede	39
Figura 15 – Fluxograma do DCS para a otimização da rede óptica.	42
Figura 16 – Rede com três nós de origem (N1, N2 e N3) e um nó de destino (N4).....	44
Figura 17 – Representação de uma única solução e de múltiplas possíveis soluções da matriz Y.....	45
Figura 18 – Etapa Y e X.....	45
Figura 19 – Representação gráfica de três possíveis soluções.....	46
Figura 20 – Etapa <i>getcuckoo</i>	47
Figura 21 – Etapa <i>newnest</i>	47
Figura 22 – Fluxograma DCS-GA.....	49
Figura 23 – <i>Crossover</i> e Mutação.....	51
Figura 24 – Rede <i>backbone</i> OTN/WDM (DEOLIVEIRA; DESOUZA; VIEIRA, 2020). ..	53
Figura 25 – Gráfico dos resultados de acordo com os parâmetros escolhidos.....	55
Figura 26 – Comparativo metaheurísticas, $k=5$ caminhos mais curtos.....	56
Figura 27 – Comparativo metaheurísticas, $k=20$ caminhos mais curtos.....	56
Figura 28 – Topologia de melhor custo \$545,20.....	58
Figura 29 – Rede 02 - OTN/DWDM.	59

LISTA DE TABELAS

Tabela 1 – Escoamento de demanda.....	39
Tabela 2 – Terminologia equivalente usada no DCS-GA.....	48
Tabela 3 – Demanda prevista para a Rede OTN/WDM.....	54
Tabela 4 – Custos dos equipamentos WDM.....	54
Tabela 5 – Valores de Parâmetros de configuração do CS.....	55
Tabela 6 – Comparativo de custos entre as Metaheurísticas com $k=5$	55
Tabela 7 – Comparativo de custos entre as Metaheurísticas considerando $k=20$ caminhos mais curtos.....	57
Tabela 8 – Tempo de execução, 5 caminhos candidatos.....	57
Tabela 9 – Tempo de execução, 20 caminhos candidatos.....	57
Tabela 10 – Demanda prevista para a Rede 02 OTN/DWDM.....	58
Tabela 11 – Comparativo metaheurísticas - Rede 02.....	59

LISTA DE ABREVIATURAS E SIGLAS

ACO	<i>Ant Colony Optimization</i>
AG	Algoritmo Genético
CapEx	<i>Capital Expenditure</i>
CS	<i>Cuckoo Search</i>
DCS	<i>Discrete Cuckoo Search</i>
DCS-GA	Algoritmo Discrete Cuckoo Search (DCS) hybrid with Genetic Algorithm (GA)
DDO	Dimensionamento de Dispositivos Ópticos
DTH	<i>Digital Transport Hierarchy</i>
ERBs	Estações Rádio Bases
FA	<i>Firefly Algorithm</i>
FEC	<i>Forward Error Correction</i>
HFA	<i>Hibridy Firefly Algorithm</i>
IoT	<i>Internet of Things</i>
IP	<i>Internet Protocol</i>
ISP	<i>Internet Service Provider</i>
ITU	<i>International Telecommunications Union</i>
LF	<i>Lévy Flight</i>
MILP	<i>Mixed Integer Linear Programming</i>
OCC	<i>Optical Channel Carrier</i>
OCh	<i>Optical Channel</i>
ODU	<i>Optical Channel Data Unit</i>
OMS	<i>Optical Multiplexing Section</i>
OpEx	<i>Operation Expenditure</i>

OPU	<i>Optical Channel Payload Unit</i>
OSC	<i>Optical Supervisory Channel</i>
OTH	<i>Optical Transport Hierarchy</i>
OTN	<i>Optical Transport Network</i>
OTS	<i>Optical Transport Section</i>
OTU	<i>Optical Channel Transport Unit</i>
PLI	Programação Linear Inteira
POC	Problema de Otimização Combinatorial
PSO	<i>Particle Swarm Optimization</i>
PTD	<i>Physical Topology Design</i>
QoS	<i>Quality of Service</i>
RA	<i>Regenerator Assignment</i>
RP	<i>Regenerator Placement</i>
RWA	<i>Routing Wavelength Assignment</i>
SA	<i>Simulated Annealing</i>
SDH	<i>Synchronous Digital Hierarchy</i>
SONET	<i>Synchronous Optical Networking</i>
TF	Topologia Física
TV	Topologia Virtual
WAN	<i>Wide Area Network</i>
WDM	<i>Wavelength Division Multiplexing</i>

SUMÁRIO

1	Introdução	14
1.1	Problema e Motivação	14
1.2	Proposta de Solução	15
1.3	Objetivos.....	17
1.3.1	Objetivo Geral	17
1.3.2	Objetivos Específicos.....	17
1.4	Contribuições do Trabalho	18
1.5	Organização do Texto.....	18
1.6	Publicações	19
2	Revisão de Literatura	20
2.1	Sistemas de Telecomunicações	20
2.1.1	Redes de Transportes OTN/WDM.....	22
2.1.2	Projeto de Rede Óptica.....	24
2.2	Programação Linear.....	25
2.2.1	Formulação Nó-Arco	27
2.2.2	Formulação Arco-Caminho.....	27
2.2.3	Algoritmo k -Caminhos.....	28
2.3	Algoritmo Genético.....	28
2.3.1	Aptidão e Seleção.....	29
2.3.2	<i>Crossover</i>	30
2.3.3	Mutação	32
2.3.4	Elitismo.....	32
2.3.5	Critério de Parada	32
2.4	Algoritmo <i>Cuckoo Search</i> (CS).....	33
2.5	Algoritmo <i>Discrete Cuckoo Search</i> (DCS)	34
2.6	Algoritmo Busca Cuco Discreta Híbrido com o Algoritmo Genético (DCS-GA).....	36
3	Metodologia Proposta para a Otimização do <i>Design</i> de Redes de Fibra Óptica	38
3.1	Modelagem da Rede	38
3.2	Formulação do Problema.....	40
3.3	DCS para Otimizar a Rede OTN/WDM.....	42
3.3.1	População inicial.....	42
3.3.2	<i>Ranking</i> de Soluções	44
3.3.3	Estágio <i>Getcuckoo</i>	45

3.3.4	Estágio <i>Newnest</i>	46
3.3.5	Estágio <i>Emptynest</i>	47
3.4	Algoritmo DCS híbrido com GA (DCS-GA) para Otimizar a Rede OTN/WDM	48
3.4.1	<i>Crossover</i>	49
3.4.2	Mutação	51
4	Resultados	52
4.1	Problema de Validação	52
4.2	Simulação	53
4.3	Comentários Finais	59
5	Conclusão	61
5.1	Trabalhos Futuros	62
	Referências.....	63

1 INTRODUÇÃO

1.1 Problema e Motivação

A pesquisa operacional é a aplicação de métodos científicos a problemas complexos para auxiliar no processo de tomada de decisões, tais como projetar, planejar e operar sistemas em situações que requerem alocações eficientes de recursos escassos. Este trabalho destaca a importância da pesquisa operacional na engenharia de produção, em particular, envolvendo a otimização do problema de planejamento da rede (YANASSE *et al.*,).

Tecnologias emergentes e serviços de comunicações vem estabelecendo mudanças substanciais aos sistemas de telecomunicações. Tais paradigmas estão acontecendo em grande escala para atender a quarta revolução industrial (Indústria 4.0), Internet das Coisas (IoT- *Internet of Things*), sistemas de comunicações móveis 5G e 6G e computação em nuvem (ALSHARIF *et al.*, 2020; KUMAR; GUPTA, 2017; LI; XU; ZHAO, 2018; LIU; DENG, 2020; MUNTAZ *et al.*, 2017). Entretanto, esse conjunto de situações faz com que a demanda por internet aumente de forma significativa. Esse aumento faz surgir um grande número de desafios complexos que os tomadores de decisões devem enfrentar.

As tecnologias das redes ópticas oferecem um aumento geral na taxa de transmissão de 100 Gbit/s, 400 Gbit/s ou até mesmo 1 Tbit/s (OHARA *et al.*, 2012). A possibilidade de usar eficazmente essas elevadas taxas de *bits* em uma rede para a necessidade dos usuários com diferentes demandas, requer um ambiente em que a estrutura da rede óptica seja projetada de tal forma que o aumento dessas demandas não influencie na arquitetura de rede, dando a possibilidade de suprir a capacidade de cada *link* com folga suficiente para aumentos futuros.

O problema de *design* de rede representa um dos mais desafiadores na indústria de telecomunicações, pois se refere a um problema de otimização combinatorial. Problemas com essa característica não se pode resolver por método exato a não ser que grande esforço computacional seja exigido, o seu conjunto de soluções está representado de forma discreta (FERNANDEZ; JUAN; TERRÉN, 2018), resultando em um problema NP-completo (SAENGUDOMLERT, 2014a) e é um problema formado por vários subproblemas, como o projeto de topologias físicas (TF) e virtuais (TV), problemas de locação de recursos de enlaces e nós, problemas de proteção na falha de enlaces e nós, entre outros (CHEKURI, 2007). A limitação orçamentária, naturalmente, é outro fator a ser previsto, pois nem sempre é possível implantar todos os sistemas necessários ao atendimento pleno da demanda. O dimensionamento de sistemas precisa contemplar fatores técnicos e econômicos que vão além da tarefa de planejar a rede objetivando o custo mínimo, seja na implantação,

aluguel, manutenção e/ou operação, portanto, são necessárias técnicas computacionais de otimização para esta tarefa. Implantar soluções que signifiquem garantia de participação no mercado e receitas compensadoras é uma questão de sobrevivência para as empresas (DESOUSA *et al.*, 2014).

O *design* de rede de transporte óptica pode ser conceituada como uma estrutura física composta de fibra óptica, receptores, transmissores, em que o pacote de dados deve ser escoado entre nós finais e arbitrários, de forma que garanta um mínimo de Qualidade do Serviço (QoS - *Quality of Service*). Nessa arquitetura os nós são as cidades/países/continentes e a rede de transporte (*backbone*, em inglês) é a estrutura física (*link*, fibra óptica) que conecta os nós. Dependendo da metodologia abordada no *design*, o processo pode se tornar lento e caro. Logo, um design de rede viável é aquele que minimiza o custo total, satisfazendo a demanda dos usuários e respeitando a capacidade de cada *link*.

Pode-se classificar o tipo de rede de acordo com as informações sobre o tráfego em três categorias: a) determinístico, b) estocástico e c) robusto (DIAZ; ROA-PINTO; LUCKEN, 2013). Em uma rede determinística se conhece o padrão de tráfego, em uma rede estocástica trabalha-se com a distribuição probabilística do padrão de tráfego e em um desenho robusto somente se é conhecido as dimensões do tráfego. A rede robusta é uma rede complexa capaz de suportar falhas e perturbações, fato comum aos complexos sistemas que elas representam, dessa forma, a robustez de uma rede está ligada o número de falhas que ela tolera sem que a mesma seja transformada em um conjunto de grupos fragmentados.

Neste contexto, o planejamento do projeto robusto de uma rede enfatiza a determinação estratégica ótima para alocar e fluir toda a demanda de tráfego. Esse planejamento pode ser feito por dois modos, o primeiro, aprecia a experiência do projetista e o segundo, o projeto estratégico conta com algoritmos que tem a primícia de sistema de apoio a tomada de decisão (DESOUSA *et al.*, 2014).

1.2 Proposta de Solução

Para problemas do mundo real, que possuem características combinatória e estão sujeitos a dinâmicas ambientes, como os citados, algoritmos metaheurísticos estão sendo fortemente apontados como escolha para os resolver. Muitas metaheurísticas são inspiradas na natureza ou em processos biológicos evolucionários, que estão sempre sujeitos a mudanças de ambientes (YANG; JIANG; NGUYEN, 2012), que de forma geral utilizam combinação de escolhas aleatórias e conhecimento histórico dos resultados anteriores adquiridos pelo método para se guiarem e realizar suas buscas pelo espaço de pesquisa em vizinhanças dentro do espaço de pesquisa, o que evita paradas prematuras em ótimos locais.

As metaheurísticas são algoritmos de alto nível que coordenam heurísticas e regras simples para encontrar soluções quase ótimas para Problemas de Otimização Combinatorial (POCs). Esses POCs podem ser encontradas em diversas áreas como a logística, os transportes, os cuidados de saúde, a produção, as cidades inteligentes e os sistemas de telecomunicações (YANG; JIANG; NGUYEN, 2012). O objetivo típico é encontrar a melhor solução possível entre um conjunto vasto de combinações factíveis (BLUM; ROLI, 2003). A maioria desses problemas são NP-completo e de grande escala, a heurística e a metaheurística tem sido cada vez mais usada para lidar com eles (MUSUMECI *et al.*, 2019).

Nas metaheurísticas destacam-se suas características chaves como a intensificação e diversificação. A intensificação usa informações locais no processo de busca como gerador de melhores soluções. A diversificação explora o espaço de busca mais detalhadamente e ajuda a gerar novas soluções. Vale destacar algumas peculiaridades acerca dessas características, por exemplo, muita intensificação fará o processo de otimização convergir rapidamente e pouca intensificação causará uma convergência prematura, conseqüentemente, podendo gerar soluções erradas ou pouco precisas.

Muita diversificação pode aumentar a probabilidade de se encontrar a solução ótima global, em contrapartida, o processo se torna lento e com baixa taxa de convergência. O ideal é usar um equilíbrio entre intensificação e diversificação, sendo a *performance* aleatória na busca local para encontrar uma melhor solução global. Durante o processo de busca, critérios de parada devem ser apontados, como por exemplo, um número fixo de gerações em que a melhor solução é adotada, ou até mesmo o próprio critério de melhor solução pode ser usado (CRUZ *et al.*, 2020).

Dentro do conjunto de metaheurísticas, as bio-inspiradas em inteligência de enxame é amplamente usada em redes ópticas (FERNANDEZ; JUAN; TERRÉN, 2018; MATA *et al.*, 2018; YANG; CHIEN; TING, 2015), como o algoritmo de otimização de enxame de partículas (PSO- *Particle Swarm Optimization*) (PAPAGIANNI, 2008), colônia de formigas (TRIAY; CERVELLO, 2010) e algoritmo de vaga-lume (*Firefly*) (RUBIO; VEJA; GONZÁLEZ, 2014; HARUNA; JINNO; NISHIO, 2015), o clássico algoritmo genético (EIRA *et al.*, 2014; YANG, 2010; DIN, 2017; DIN, 2015) e algoritmo híbrido *Firefly* com algoritmo genético (DEOLIVEIRA; DESOUZA; VIEIRA, 2020).

conforme revisado na literatura (LIMA; DEOLIVEIRA; CARNEIRO, 2021), existe uma carência do uso de algoritmos contínuos em problemas combinatoriais, dado ao fato de a característica do problema somada com a complexidade de adaptação dos algoritmos resultam em uma otimização mais complexa. O algoritmo *Cuckoo Search*(CS), por exemplo, é uma metaheurística inspirado na natureza desenvolvido por Xin-She Yang e Deb (YANG; SUASH, 2009) e foi desenvolvido para ser aplicado em problemas contínuos de otimização. Sua forma adaptada para ser utilizada em problemas de otimização discretas

(*Discrete Cuckoo Search* - DCS) é mostrado em (BELLO-SALAU *et al.*, 2020; GANDOMI; YANG; ALAVI, 2013; OUAARAB; AHIOD; YANG, 2014), suas características discretas se assemelham com o problema do *design* de rede e ainda não foi aplicado no *design* de rede de fibra óptica.

Assim, é sabido que a rede óptica está cada vez mais sujeita a inovação tecnológica para poder aproveitar melhor a infraestrutura atual para as altas taxas de transmissão. Em contrapartida, a complexidade da rede está diretamente ligada à utilização eficiente dos seus recursos, à medida que a rede se torna mais complexa a utilização desses recursos se torna um problema cada vez mais complexo. Com isso, cada vez mais algoritmos está sendo utilizado para otimizar esse problema e servir como um sistema de apoio para auxiliar no planejamento de rede. É proposto então analisar o desempenho do algoritmo Busca Cuco Discreto (*Discrete Cuckoo Search* - DCS) e do algoritmo híbrido DCS com algoritmo genético (GA), intitulado de DCS-GA, no planejamento de rede óptica.

1.3 Objetivos

1.3.1 Objetivo Geral

Propor um sistema computacional semiautônomo através de heurísticas modernas de otimização no estado-da-arte para o apoio aos projetos de redes de fibra óptica.

1.3.2 Objetivos Específicos

Desenvolver modelo computacional para representação da rede de fibra óptica.

Desenvolver modelo de otimização por Programação Linear Inteira Mista (MILP) com a modelagem arco-caminho agregado com algoritmo genético e busca cuco para auxiliar no planejamento de uma rede óptica.

Aplicar o algoritmo *Discrete Cuckoo Search* (DCS) e o algoritmo *Discrete Cuckoo Search* híbrido com *Genetic Algorithm* intitulado de DCS-GA para projetar a configuração da rede de modo a reduzir o custo de implantação uma rede óptica *backbone* e uma rede de pequeno porte.

Aplicar as metodologias propostas em uma rede real OTN/WDM realista em termos de dados disponíveis para planejamento.

Dimensionar a rede através da alocação dinâmica de recursos considerando uma demanda escoada por vários nós da rede.

1.4 Contribuições do Trabalho

O modelo proposto neste trabalho permite contemplar o atendimento de uma matriz de tráfego peculiar. Essas matrizes são compostas de pares de nós, origem e destino. Neste trabalho, o algoritmo bio-inspirado utilizado no modelo ainda não foi abordado no problema de interesse, dando exclusividade para essa aplicação.

A modelagem arco-caminho juntamente com o MILP foram utilizados, permitindo a análise de cenários da matriz de demanda que possui diversos nós de destinos, nesse caso, foram avaliados dois nós de destinos. O modelo possibilitou o dimensionamento da rede com folga, esse requisito de planejamento pôde ser atendido, garantindo o carregamento de demanda por *link* no conjunto de restrições de capacidade técnica.

Neste trabalho, foi proposta uma versão do algoritmo *Discrete Cuckoo Search* híbrido com o *Genetic Algorithm* (DCS-GA) que mostrou seu desempenho em ambas as redes propostas. Na rede de grande porte, o DCS-GA trouxe o menor custo (\$ 545,20) quando comparado com as técnicas DCS, *Firefly*, *Firefly* Híbrido e algoritmo genético (GA), já o modelo proposto DCS levou menos tempo de processamento em relação à sua versão híbrida. Os resultados obtidos pelo algoritmo híbrido são um conjunto de topologias (soluções) com custos reduzidos com pequena variabilidade entre as soluções obtidas, em que dos 50 links propostos, apenas 26 foram utilizados para o escoamento da demanda total da rede. Foram utilizados 5 *links* de capacidade de 400 Gbit/s, 4 *links* de 100 Gbit/s e 17 *links* de capacidade 40 Gbit/s. Cabendo ao planejador a decisão final, de qual topologia mais se enquadra a sua realidade.

1.5 Organização do Texto

O texto deste trabalho está dividido da seguinte forma: no Capítulo 2- apresenta-se a revisão de literatura sobre o sistema de comunicação considerado. O conceito sobre programação inteira linear mista também é apresentado, logo após a formulação é apresentada com arco-caminho, destacando a importância dos caminhos candidatos escolhidos pelo planejador ou pelo algoritmo (*k*-caminhos). As técnicas metaheurísticas também são descritas.

O Capítulo 3- apresenta os modelos matemáticos MILP e a formulação do problema de interesse, neste capítulo também são descritos os algoritmos genético e cuco, seguidos de suas adaptações para a sua correta aplicação no problema.

No Capítulo 4- são apresentados os resultados das simulações dos modelos aplicados em uma rede OTN/WDM de grande porte na implantação de *backbone* e uma rede de pequeno porte pertencente ao SNDlib. Os resultados das simulações computacionais trazem diversidade à técnica de resolução, uma topologia de solução eleita de melhor

custo para a rede *backbone*, a matriz de demanda, entre outros. O Capítulo 5 apresenta as conclusões obtidas durante a realização deste trabalho.

1.6 Publicações

Artigos aceitos em congresso:

1. R.A. Lima, M. L. Carneiro e B. Q. DeOLIVEIRA Algoritmo de Busca Cuco Discreto Aplicado ao Planejamento de Redes Ópticas, *Encontro Nacional de Engenharia de Produção (ENEGEP)*, 2021.
2. R.A. Lima, M. L. Carneiro e B. Q. DeOLIVEIRA Otimização da Rede de Transportes Ópticas: Revisão e Complexidade, *Encontro Nacional de Engenharia de Produção (ENEGEP)*, 2021.

Capítulos de Livro:

1. LIMA, R.; DEOLIVEIRA, B.; CARNEIRO, M. Algoritmo Busca Cuco Discreto Aplicado ao Planejamento de Redes Ópticas. In: LIMA, R.; DEOLIVEIRA, B.; CARNEIRO, M. Coletânea Especial de Engenharia de Produção 2. Itajubá: KREATIK, 2021. Cap. 03, p. 27-40.
2. LIMA, R.; DEOLIVEIRA, B.; CARNEIRO, M. Otimização da Rede de Transportes Ópticas: Revisão e Complexidade. In: LIMA, R.; DEOLIVEIRA, B.; CARNEIRO, M. Coletânea Especial de Engenharia de Produção 2. Itajubá: KREATIK, 2021. Cap. 16, p. 219-229.

Artigo submetido em periódico:

LIMA, Rayane; Vieira, Flávio; DeOliveira; Bruno e Carneiro, Marcos, Optimization of Optical Transport Networks using hybrid Discrete Cuckoo Search Algorithm, *Computational Optimization and Applications*, 2022.

2 REVISÃO DE LITERATURA

Esse Capítulo descreve de forma geral o sistema de telecomunicações (Seção 2.1), destacando a rede de transporte óptica e a caracterização do projeto de rede óptica. Em seguida os conceitos de programação linear são apresentados na Seção 2.2 onde é abordado as formulações como Nó-arco, Arco-caminho e o Algoritmo k -caminhos que auxiliam na caracterização do problema. Os modelos de otimização propostos são baseados nessas programações. As técnicas de inteligência artificial como, algoritmo genético, algoritmo busca cuco discreta e busca cuco discreta híbrida estão presentes nas Seções 2.3, 2.4 e 2.5, respectivamente.

2.1 Sistemas de Telecomunicações

A palavra “tele” significa distância, logo o termo “telecomunicações” sugere a comunicação à distância. Um sistema de comunicação transmite informação de um lugar ao outro, mesmo separados por poucos quilômetros ou por distâncias transoceânicas. O sistema de comunicações ópticos usam ondas eletromagnéticas de alta frequência (100 THz) na luz visível ou próximo à região infravermelho do espectro eletromagnético. O uso da luz para comunicação vem desde a antiguidade, se interpretarmos a comunicação óptica em um amplo sentido (SHANNON, 1949). A maioria das civilizações tem usado espelhos, faróis de fogo, ou sinais de fumaça para transmitir uma parte da informação (tal como a vitória de uma guerra). Essencialmente a mesma ideia tem sido usada no final do século XVIII através de lâmpadas de sinalização, bandeiras e outros dispositivos semafóricos.

As telecomunicações passam por uma grande expansão do tráfego de longa distância, proporcionada pela expansão do sistema telefônico nacional e, principalmente, pelo avanço exponencial do tráfego de internet (*Internet Protocol* - IP), que é caracteristicamente de longa distância. Com isto, as redes que estavam tipicamente consolidadas davam lugar a redes com novas tecnologias (RAMAMURTHY; SAHASRADUDDHE; MUKHERJEE, 2003). A fase de pesquisa sobre o sistema de comunicação sobre fibra óptica começou por volta de 1975. Substituindo redes de cobre, a fibra óptica surgia como um meio de alternativo para transmissão de dados (IANNONE, 2016). A fibra óptica é um cabo que fornece uma transmissão com baixa perda e grande taxa de transmissão. Uma rede óptica é composta pelos cabos de fibra óptica que transportam canais de luz, combinado com equipamentos que são capazes de processar a luz (FILHO; BASTOS, 2010).

A capacidade de transportar vários canais de luz em uma única fibra marcou um

dos primeiros avanços dessa tecnologia. Cada comprimento de onda (λ) é transportado em uma frequência óptica e multiplexada em uma única fibra. Os sistemas WDM (*Wavelength Division Multiplexing*) possibilitaram a multiplexação de dezenas de canais, cada um em um comprimento de onda (e frequência) específico, numa mesma fibra (MONTEIRO, 2015). Isto multiplicou a capacidade de transmissão pelo número de comprimentos de onda multiplexados.

As operadoras de telefonia móvel (celular) utilizam fibras ópticas para interconectar suas Estações Rádio Base (ERBs), estações de rádio que captam o sinal dos assinantes móveis. Operadoras de TV por assinatura empregam o uso de fibras ópticas para que o sinal chegue até seus usuários, canais com alta definição. Os Provedores de Acesso à Internet (ISP- *Internet Service Provider*) também utilizam, essa tecnologia para fornecer acesso à banda larga aos seus assinantes.

As redes de transportes ópticas podem ser divididas em níveis hierárquicos baseados na geografia (Figura 1), cuja suas diferenças consistem na quantidade de clientes associados a rede. As conexões entre redes regionais são feitas por meio da rede *backbone* de grandes distâncias, podem ser compostas por milhões de clientes e normalmente abrangem milhares de quilômetros. Uma rede *backbone* assume topologias em anel ou ponto-a-ponto, são necessários regeneradores de sinais em cada nó e alguns pontos intermediários do enlace, a fim de manter a integridade do sinal. O local em que esses regeneradores e equipamentos de multiplexação/demultiplexação de sinais ópticos, ficam alojados são chamados de *sites*.

Uma rede regional transporta a parte do tráfego que se estende entre áreas metropolitanas e comporta centenas de milhares de clientes, tendo extensão geográfica de centenas de milhares de quilômetros. A rede metropolitana disponibiliza e compartilha recursos aos clientes que estão no nível de acesso. Ela é responsável por otimizar recursos e estabelecem conexões em menor tempo. Sua topologia, normalmente, é em anel ou malha.

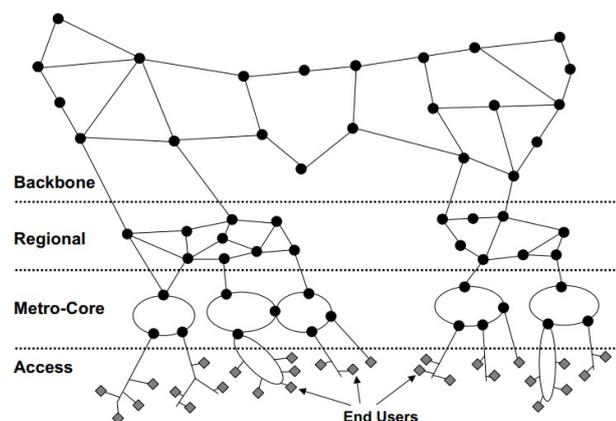


Figura 1 – Networking hierarchy based on geography. (SIMMONS, 2008)

As redes de acesso distribuem/coletam tráfego para os clientes da rede. Permitem a conexão do cliente ao seu provedor de serviços imediatos, neste caso, operadoras de telecomunicações. Sua capacidade de multiplexar é baixa e oferece meios físicos dedicados a clientes de pequeno porte. Possui topologia barramento, estrela ou árvore, alimenta dezenas a centenas de clientes e alcançam poucos quilômetros. Possui serviço de redundância com um ou dois *hubs* em caso de falha no enlace para conectar à rede metropolitana. Neste trabalho será estudado o nível *backbone* da rede.

2.1.1 Redes de Transportes OTN/WDM

Quando a SONET/SDH (*Synchronous Optical Networking / Synchronous Digital Hierarchy*) foi desenvolvida originalmente no início dos anos 1990, as redes de dados e voz eram projetadas e montadas separadamente (TESSINARI, 2011). Entretanto, quase imediatamente, a SONET/SDH estava sendo usada para combinar o tráfego de dados e voz em uma única rede de transporte, com elementos da rede de dados adotando interfaces e protocolos de transportes de voz. Foram desenvolvidas adaptações para mapear o tráfego de dados nos quadros de SONET/SDH para que as operadoras pudessem usar as redes SONET/SDH. No entanto, isso se provou cada vez mais ineficiente, por que as cargas úteis de voz e dados são construídas com taxas consideravelmente diferentes.

A OTN (*Optical Transport Network*) representa um avanço técnico em redes ópticas e uma oportunidade de negócios para as operadoras e os provedores de serviços. Com a OTN pode evoluir para uma sobreposição de malha que combina cargas úteis da SONET/SDH, *Ethernet* e OTN, oferecendo um meio eficaz de criar uma infraestrutura modernizada e ainda transporta tráfego de outra geração (MAZDA, 2014).

As tecnologias de transporte anteriores, como SONET e SDH, não eram projetadas para serviços dominados por pacotes e de alta capacidade que exigem capacidade mínima de 40Gbit/s. Tendo isso em mente, a OTN, foi padronizada pela ITU (*International Telecommunications Union*) como G.709. A hierarquia do OTN mostra o sistema de transmissão como um todo, desde seu protocolo em construção até a terminação em um quadro (Figura 2). Sendo definido pelas recomendações ITU-T G.709, G.805 e G. 872 (GILCHRIST, 2015). A hierarquia se divide em duas camadas, uma o transporte óptico (*Optical Transport Hierarchy -OTH*) e outra parte digital (*Digital Transport Hierarchy DTH*) (CÉSAR, 2014).

A sua arquitetura é composta pelas camadas:

- ◆ *Optical Channel Payload Unit* (OPU);
- ◆ *Optical Channel Data Unit* (ODU);
- ◆ *Optical Channel Transport Unit* (OTU);

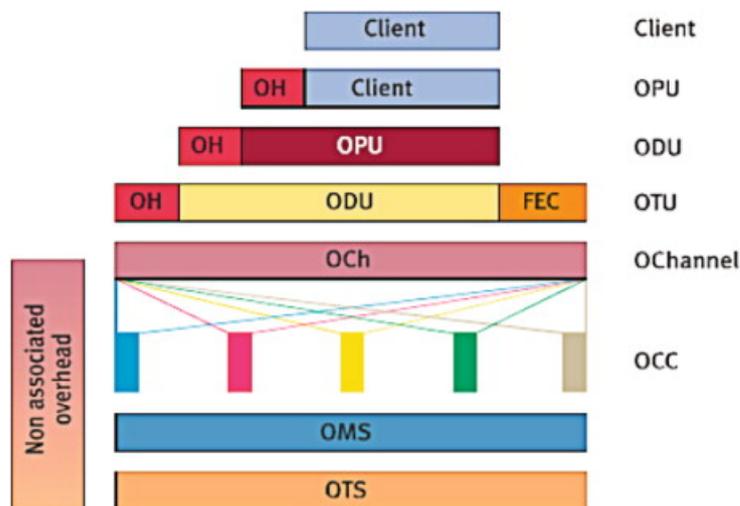


Figura 2 – OTN Hierarchy (JORGE, 2012).

- ❖ *Optical Channel (OCh)*;
- ❖ *Optical Multiplex Section (OMS)*;
- ❖ *Optical Transport Section (OTS)*.

No domínio elétrico, a OPU encapsula o sinal de carga que representa o cliente (SDH, SONET, IP *Gigabit Ethernet*, etc.) e realiza um pequeno rearranjo no sinal para ser transmitido. Na OPU é colocado um cabeçalho (*flag*) na fonte, e no destino é retirada a informação de *flag* sem modificação na rede. Este *flag* é somente uma sinalização de que o dado está sendo encaminhado ao ponto de destino.

A ODU encapsula a OPU e adiciona um *flag* para que seja controlado até seu destino. A OTU encapsula a ODU, adiciona o *Forward Error Correction* (FEC) para a correção de erros das camadas anteriores e adiciona um cabeçalho de monitoração, logo ocorre a conversão eletro-óptica do dado, isto é, a informação passa do domínio elétrico para o óptico, este sinal é direcionado para o canal óptico, o *Optical Channel (OCh)*.

O sinal é então qualificado e arranjado para que em seguida possa ser encaminhado para a *Optical Channel Carrier (OCC)*, transportada por sua camada inferior à OMS. A função da OMS é adequar o sinal do cliente com o de outros clientes para poder ser encaminhado ao seu destino. A camada OTS monitora e controla o sinal, enquanto ele percorre todo o caminho óptico. Se a vazão do sinal for de alto nível, em cada OTN é implementado um canal de supervisão *Optical Supervisory Channel (OSC)*.

A Figura 3 mostra as três camadas ópticas hierárquicas do OTN em execução. Este trabalho está focado na otimização estratégica dos enlaces de fibra óptica no meio físico. O planejamento ótimo resulta em uma rede de custo reduzido e conseqüentemente economia em equipamentos, como, por exemplo, amplificadores de linhas, emendas, fibras

compensadoras de dispersão, etc. Esses equipamentos além de aumentar o custo da rede, traz também ruídos, o que afeta a qualidade do sinal ao usuário final.

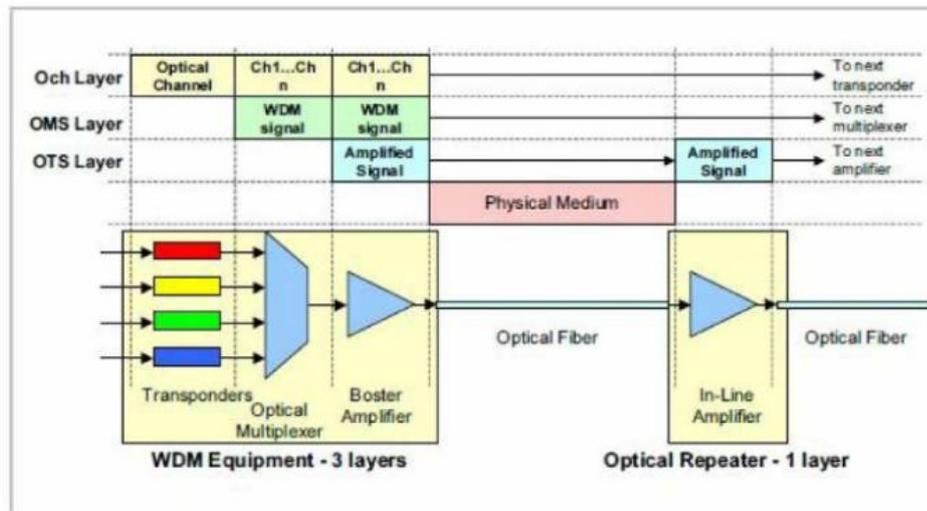


Figura 3 – Representação das três camadas ópticas hierárquicas do OTN em execução (GILCHRIST, 2015).

As redes OTN, entretanto, também apresentam suas desvantagens. O acúmulo de penalidades geradas na camada óptica podem degradar a comunicação, tornando a qualidade do sinal recebido inaceitável para uma comunicação satisfatória (RAI *et al.*, 2007; STRAND; CHU; TRACK, 2001). Existem três estratégias que podem ser abordadas para solucionar esse problema, são elas: a utilização de dispositivos ópticos menos ruidosos (PERERIRA *et al.*, 2009), a utilização de regeneradores em alguns nós na rede (SHEN; TUCKER, 2007; RAMAMURTHY *et al.*, 1999) e/ou o desenvolvimento de algoritmos de otimização capazes de encontrar rotas que minimizem o custo e o impacto das penalidades da camada óptica (RAI *et al.*, 2007). Este trabalho aborda a terceira estratégia.

2.1.2 Projeto de Rede Óptica

As redes ópticas são importantes para compor as redes de telecomunicações que estejam preparadas para as demandas atuais da sociedade. O objetivo é otimizar a relação custo-desempenho envolvida na implementação (diminuir custos e aumentar o desempenho). Logo, os custos da rede são dois: investimentos relativos à compra e instalação de dispositivos, também chamado de CapEx (*Capital Expenditure*) e os investimentos relacionados à manutenção e operação da rede, também chamado custo operacional ou (OpEx *Operation Expenditure*) (SYGLETOS; TOMKOS; LEUTHOLD, 2004).

Para um determinado projeto de rede, podem existir soluções com baixo custo e baixo desempenho e soluções de alto custo e alto desempenho, e todo esse conjunto de soluções entre esses dois extremos, resulta em uma relação custo-desempenho otimizada. Logo, a maneira mais geral de se criar um projeto de uma rede e de forma flexível é buscar

não somente uma solução para o problema, mas um conjunto de soluções que otimizem o parâmetro custo/desempenho.

Os elementos que influenciam de forma preponderante o custo e o desempenho da rede são: o dimensionamento das características dos dispositivos ópticos empregados na rede Dimensionamento dos Dispositivos Ópticos (DDO), o algoritmo para o roteamento e atribuição de comprimentos de onda (RWA *Routing Wavelength Assignment*), algoritmo utilizado para a colocação de regeneradores (RP *Regenerator Placement*), algoritmo de utilização desses regeneradores (RA *Regenerator Assignment*) e a projeto da topologia física da rede (PTD *Physical Topology Design*). Esse último será abordado nesse trabalho.

O projeto de topologia física (PDT), aborda como os nós da rede óptica devem ser conectados, ou seja, quais são os enlaces que devem ser instalados na rede. Diretamente proporcional, quanto maior a quantidade de enlaces instalados, maior também será o CapEx da rede, e provavelmente será o seu desempenho, pois maior quantidade de recursos de infraestrutura de telecomunicações estarão disponíveis para atender os clientes finais da rede.

2.2 Programação Linear

Um problema de Programação Linear Inteira (PLI) é considerado sinônimo de Programação Inteira, no qual todas as variáveis são positivas e inteiras (BAZARAA; SHE-RALI, 2010), ou seja:

$$\text{Max ou Min } f(x) = c^T \cdot x$$

Sujeito:

$$\sum_{j=1}^n a_{ij}x_j = b_i, \quad i = 1, 2, \dots, m$$

$$x \geq 0 \text{ e inteiro ou } \in Z^+, \quad j = 1, 2, \dots, n$$

Z^+ = representa números inteiros e positivos

Onde:

$f(x)$ -Função objetivo;

x - Variáveis de decisão;

b - Lado direito das restrições;

c - Coeficiente da função objetivo;

a - Matriz "A".

A função objetivo representa o objetivo do problema de interesse, combinando fatores que proporcione um desempenho adequado respeitando o conjunto de restrição de

cada problema. Em certos problemas as variáveis assumem valores contínuos e discretos, e existe um esforço computacional para resolver o problema das variáveis inteiras binárias, nesses casos, utiliza-se a Programação Linear Inteira Mista (*Mixed Integer Linear Programming* - MILP) (BANDYOPADHYAY, 2007).

Os problemas que utilizam esse tipo de técnica são conhecidos como NP-*hard*, pois são difíceis de resolver (SAENGUDOMLERT, 2014b). No planejamento da rede de transporte o modelo matemático é dividido em dois conjuntos de variáveis de decisão:

1. Aspectos de equipamentos: corresponde à decisão de alocar (ou não) e dimensionar os equipamentos em cada vértice (ou aresta) da rede. Possui característica binária (0/1) e, para o padrão de sistemas aqui estudados, podem ser utilizados em redes de médio ou grande porte.
2. Aspectos de fluxo de demanda: modelam o caminho percorrido pela demanda da origem até o destino e possuem características reais.

Define-se como grafo, qualquer estrutura que possui vértices (ou nós) ligados por meio de arestas (ou arcos). Na Figura 4, um exemplo de um grafo simples de três nós e três arcos. A arquitetura de um grafo pode ser associada à arquitetura de rede de transporte óptica, em que os nós (de demanda) são as cidades/países e as arestas são os *links*, ou seja, a fibra óptica que conecta as cidades/países/continentes.

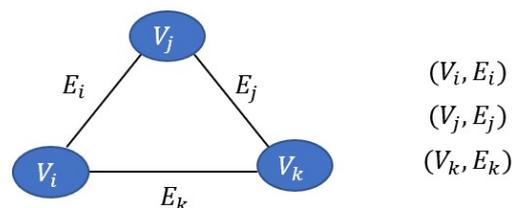


Figura 4 – Grafo simples com três vértices e três arestas.

Para o escoamento de dados deve-se analisar a modulação em que será tratado o fluxo de demanda que sai do nó de origem e chega ao nó de destino. Duas formulações são apresentadas: formulação nó-arco e a arco-caminho (BAZARAA; JARVIS; SHERALI, 2010). A principal diferença nessas formulações é a representação do fluxo na rede, ou seja, o grafo possui forma $G(V, A)$, V são os vértices (nós) e A são os arcos (*links*). Para a formulação nó-arco, a lei de conservação do fluxo deve ser aplicada, ou seja, o fluxo total de entrada no nó é igual ao fluxo total que sai do nó, havendo restrições de escoamento.

2.2.1 Formulação Nó-Arco

A formulação nó-arco, também conhecida como roteamento adaptativo, possui semelhança com a formulação de problemas de fluxos multiprodutos em redes (PIÓRO; MEDHI, 2004). E basicamente trabalha na conservação de fluxo em todos os nós da rede, assim, existem restrições de escoamento e conservação em todos os nós. Esta formulação apresenta um destino específico, e o fluxo total de entrada considerado no nó é igual ao fluxo de saída a partir do nó, esse fenômeno é chamado de lei de conservação do fluxo, dito isso essa formulação é mais complexa.

2.2.2 Formulação Arco-Caminho

As rotas consideradas por esta formulação constituem um subconjunto do conjunto de todas as rotas possíveis da rede. Isto pode ser uma vantagem sobre a formulação Nó-arco se considerarmos a redução da complexidade computacional do problema devido ao conjunto restrito das rotas possíveis. A matriz de incidência é formada com base na definição do conjunto de rotas (caminhos) pré-estabelecidas. A Figura 5, exemplifica possíveis caminhos para uma rede de três nós.

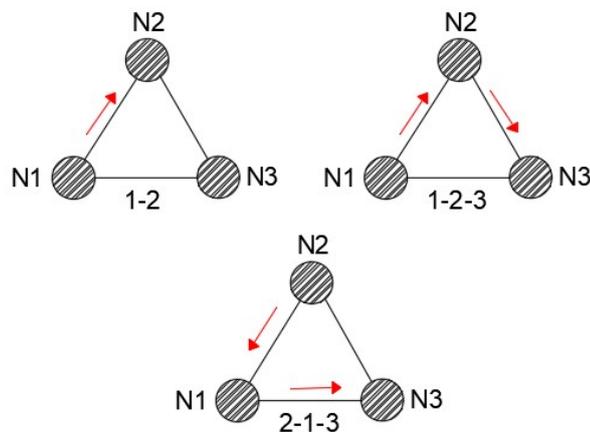


Figura 5 – Exemplos de caminhos para uma rede de três nós.

Esta formulação indica que inúmeras demandas podem ser escoadas ao mesmo tempo e disputam por recursos disponíveis que são as capacidades dos *links* (arcos). Com isso, temos a restrição referente à escolha dos caminhos da seguinte forma, a primeira opção: quando os arcos possuem capacidade definidas, a segunda opção: a capacidade precisa ser alocada no arco.

Existem duas formas para a geração dos caminhos, uma conta com uma geração manual, em que o projetista analisa os caminhos para os dados serem escoados, outra forma de geração é a automática contando com algoritmo de *k*-caminhos mais curtos (MARTINS, 2017). O que será abordado nesse trabalho.

2.2.3 Algoritmo k -Caminhos

O problema do caminho mínimo ou caminho mais curto, consiste em encontrar o melhor caminho entre dois nós. Assim resolver este problema pode significar determinar o caminho entre dois nós com o custo mínimo, ou com menor tempo de viagem.

Em uma rede indefinida, dependendo das suas características, podem existir vários caminhos entre um par de nós, sendo a origem e o outro o destino. Entre os vários caminhos aquele que possui o menor peso é então chamado caminho mínimo. Este peso representa a soma total dos valores dos arcos que compõem o caminho e estes valores podem ser: o tempo de viagem, a distância percorrida ou um custo qualquer do arco. E quando o objetivo é classificar os caminhos sem nós repetidos, o problema é chamado como classificação dos caminhos sem *loop* mais curtos do Yen (YEN, 1971).

O algoritmo sem *loop* utiliza duas listas, por exemplo, X e Y. A lista X contém os caminhos permanentes mais curtos da origem ao destino (com ordem cronológica). A lista Y contém os caminhos que serão candidatos. Antes do experimento é necessário encontrar o primeiro caminho mais curto da origem ao destino, para isso será utilizado o algoritmo em que apenas os custos positivos serão considerados, o algoritmo Dijkstra (TEXEIRA *et al.*, 2017). A ideia é que os k -ésimos caminhos mais curtos podem compartilhar arestas e subcaminhos (caminho da origem até qualquer nó intermediário dentro da rota) do caminho mais curto. Assim o caminho mais curto é selecionado e cada nó da rota fica inacessível por sua vez, isto é, remover um arco particular que vai para o nó dentro da rota.

Quando o nó estiver inacessível, estabelece a localização do caminho mais curto do nó anterior até o destino, e essa rota é inserida ao subcaminho comum e um novo caminho mais curto do nó anterior ao destino é adicionado. Então essa rota vai para a lista Y, se não estiver contido na lista X ou na Y anteriormente. Esse passo é repetido para os nós da rota, na lista Y é gerado a rota mais curta e movida para a lista X. Este processo é repetido k vezes.

Para otimização deste trabalho, a geração de k -caminhos utiliza o comprimento dos *links* candidatos da rede como dado de entrada. Estes dados podem ser disponibilizados pelo planejador (quando se tem) ou como alternativa, podem ser dados os dados geográficos dos nós da rede, e a distância euclidiana dos *links* são calculados.

2.3 Algoritmo Genético

Em meados de 1950 à 1970 o algoritmo genético foi desenvolvido por John Holland, baseado na primícia de utilizar computadores para simular sistemas biológicos (HOLLAND, 1975). Desde então surgiram novas técnicas de soluções de problemas baseados

em programação evolutiva, da qual os algoritmos genéticos se enquadram. O uso do algoritmo genético em problemas de otimização combinatorial vem crescendo (ANDRÉ *et al.*, 2013; ALSHAMI; DIABAT, 2017; PERALTA; FORGHANI; FAYAD, 2014; MANSOURI, 2015; CAMPOS *et al.*, 2016; BAUMGARTNER; REDDY; BAUSHED, 2015).

Os algoritmos genéticos permitem uma simplificação na formulação e solução de problemas de otimização, pois incorporam uma solução potencial para um problema específico em uma estrutura semelhante ao cromossomo e aplicam operadores de seleção e cruzamento a essas estruturas para preservar informações críticas relativas à solução do problema.

O processo evolutivo de um algoritmo genético se inicia com a geração de uma população de indivíduos (normalmente aleatória), ou cromossomos, que correspondem a soluções candidatas do problema. A manipulação de alguns indivíduos ocorre por um conjunto de operadores genéticos, desenvolvido pelo processo evolutivo. Esse processo de simulação de reprodução genética tem por objetivo a formação de novos indivíduos e o aumento de diversidade da população, auxiliando na busca pela melhor solução. Os indivíduos são avaliados conforme suas qualidades (*fitness*), e os mais adaptados são selecionados para a próxima geração e recombinados para formar uma nova população, através do cruzamento (*crossover*), gerando filhos. Cada indivíduo da população resultante pode sofrer alguma mutação, sendo uma alteração aleatória no cromossomo. Os critérios de paradas, geralmente adotados em algoritmos genéticos, são os indivíduos que representam uma solução aceitável para o problema e o número pré-estabelecido de gerações. Um programa genético básico pode ser descrito pelo algoritmo mostrado na Figura 6. Cada um dos indivíduos da população representa uma possível solução para o problema, ou seja, um ponto no espaço de soluções (PINHO *et al.*, 2013).

2.3.1 Aptidão e Seleção

A aptidão, também conhecida como função *fitness*, é definida através do cálculo da função objetivo, que está associado as características do projeto. A aptidão está relacionada diretamente com o nível de adaptação do indivíduo com o ambiente, e os indivíduos mais aptos passa parte do seu material genético (através da reprodução) para as gerações futuras.

A função objetivo deve atender as características do problema de interesse, e em se tratando de problemas discretos e combinatorios, um conjunto de restrições deve ser respeitado afim de não gerar soluções infactíveis.

A função objetivo é responsável, por determinar a qualidade de um indivíduo e é a única ligação leal do programa com o problema real. Na função de avaliação está contemplado, de forma numérica, os objetivos do problema (LINDEN, 2012). Indivíduos

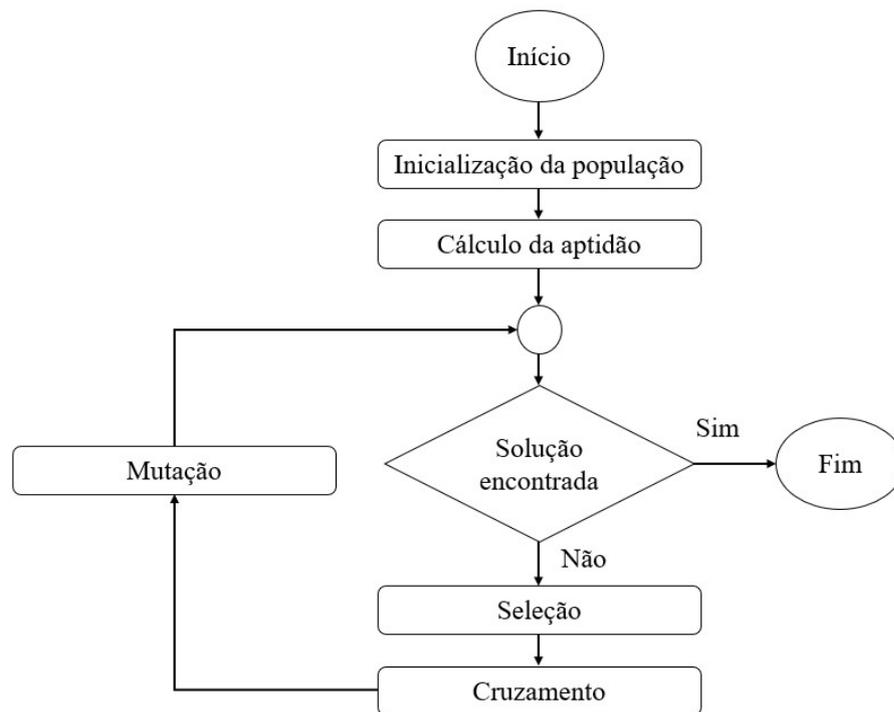


Figura 6 – Fluxo de controle do algoritmo evolutivo.

gerados mais aptos, são então manipulados para produzir uma nova população através do passo de *crossover*.

2.3.2 *Crossover*

A etapa *crossover* também chamada recombinação é um operador usado para variar a programação de um cromossomo de uma geração para a próxima. O seu funcionamento está baseado em pegar mais de uma solução progenitora e produzir uma solução descendente.

Muitas técnicas de recombinação para organismos existentes usam diferentes estruturas de dados para armazenar elas mesmas (PRATA, 2015). O *crossover* mais comum é a recombinação em um ponto, um único ponto para recombinação é selecionado em ambos os organismos progenitores. Todos os dados além do ponto selecionados são trocados entre progenitores. Os organismos resultantes são os filhos (Figura 7).

Na recombinação em dois pontos necessita que dois pontos sejam selecionados nas cadeias dos organismos progenitores. Tudo que está entre esses dois pontos é trocado entre os progenitores resultando nos filhos (Figura 8).

A recombinação uniforme os *bits* (genes) do vetor são comparados individualmente entre ambos progenitores, são aleatoriamente copiados do primeiro ou segundo pai para os filhos. Os *bits* se intercambiam com uma probabilidade fixada definida por uma taxa de

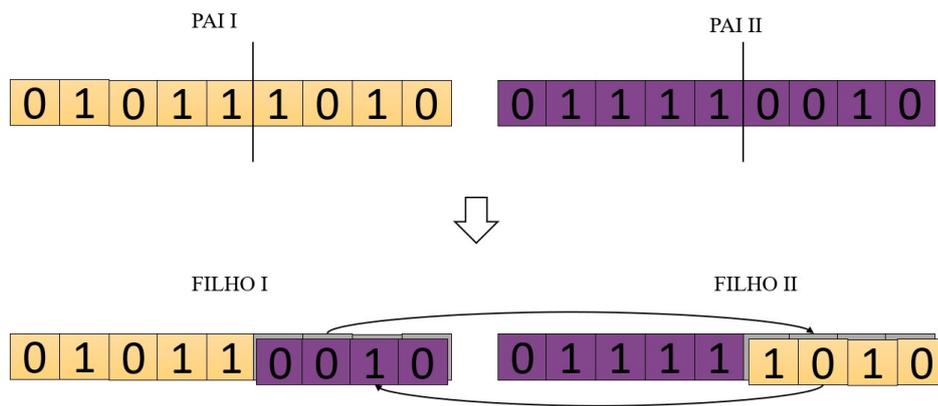


Figura 7 – *Crossover* ponto único.

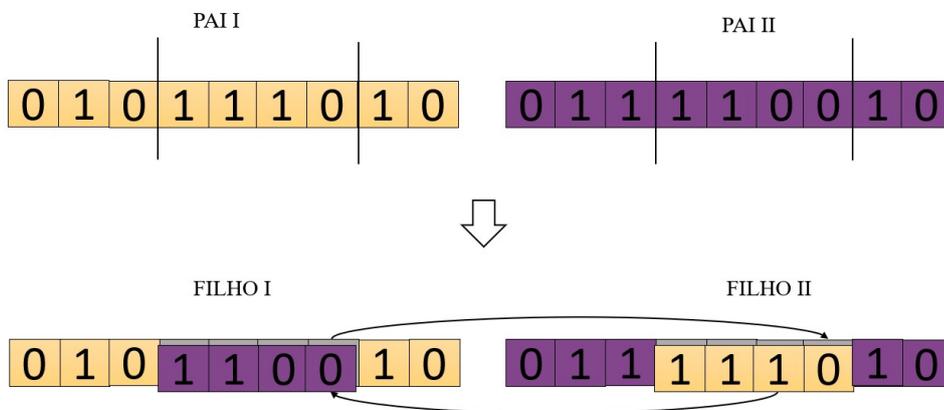


Figura 8 – *Crossover* de dois pontos.

crossover, conhecida como probabilidade de cruzamento (KONAK; COIT; SMITH, 2006) (Figura 9).

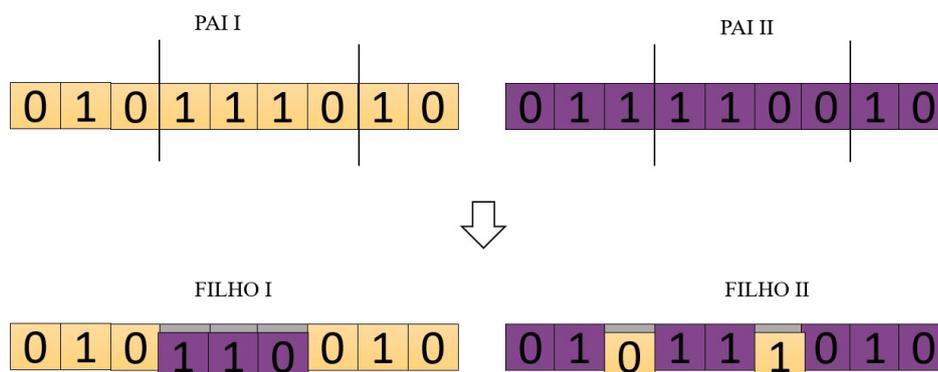


Figura 9 – *Crossover* uniforme.

É preciso a busca do equilíbrio no valor da taxa de recombinação, pois altas taxas acarretam em convergência rápida, podendo gerar perdas de estruturas de alta adaptabilidade, ou seja, podendo descartar soluções com boa chance de alcançar o valor ótimo. E taxas baixas pode deixar o algoritmo lento.

2.3.3 Mutação

A mutação é responsável de garantir uma maior análise no espaço de estados e evitar a convergência prematura do algoritmo. Um gene é alterado aleatoriamente com uma determinada probabilidade (probabilidade de mutação), essa probabilidade deve ser menor que a do *crossover*, ou seja, diversos indivíduos da nova população podem ter seus genes alterado aleatoriamente.

Esta troca é importante, pois acaba por criar novos valores de características que não existiam ou apareciam em pequena quantidade na população em análise (KONAK; COIT; SMITH, 2006). O operador de mutação é importante para a introdução e manutenção de diversidade genética da população. Portanto, a mutação assegura que a probabilidade de se chegar a qualquer ponto do espaço de busca possivelmente não será zero. A Figura 10 representa a troca de posição de um gene qualquer.

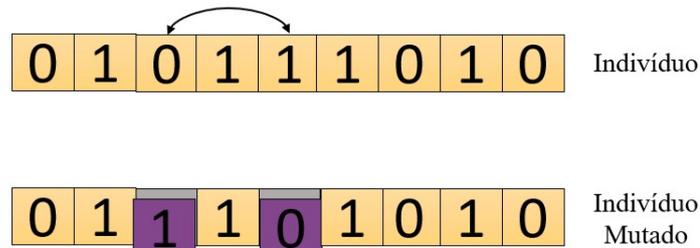


Figura 10 – Troca de posição de genes.

A probabilidade de cruzamento e probabilidade de mutação são variáveis definidas pelo usuário, neste trabalho serão adotados a probabilidade de 100% em ambas probabilidades, ou seja, toda vez que o algoritmo for executado ocorrerá o cruzamento e mutação.

2.3.4 Elitismo

O operador elitismo é responsável por forçar o algoritmo genético a reter o melhor indivíduo da geração atual, ou alguns dos melhores, na próxima geração (GOLDBERG, 1989).

2.3.5 Critério de Parada

Como critérios de parada do algoritmo em geral são usados a aptidão do melhor indivíduo em conjunto com a limitação do número de gerações e até mesmo um certo tempo máximo de iteração (HICKS, 2006).

2.4 Algoritmo *Cuckoo Search* (CS)

O algoritmo *Cuckoo Search* (CS) foi um dos últimos métodos metaheurísticos inspirados na natureza desenvolvido por Xin-She Yang e Deb (YANG; SUASH, 2009). O CS foi desenvolvido para ser aplicado em problemas contínuos de otimização e está baseado no comportamento de parasitismo de ninhada de algumas espécies cuco. O algoritmo conta com o aprimorado voo de Lévy (PAVLYUKEVICH, 2007). Algumas espécies colocam seus ovos em ninhos de outras aves para serem chocados, assim, existe a probabilidade de a ave hospedeira encontrar os ovos hóspedes e abandonar o ninho e construir em outra localização. Um grande número de espécies se envolve nessa categoria de parasitismo obrigatório. Três regras idealizadas podem ser usadas para descrever o algoritmo da busca cuco padrão:

1. Cada cuco coloca um ovo de cada vez em um ninho escolhido aleatoriamente;
2. O melhor ninho com ovos de melhor qualidade será carregado para as próximas gerações;
3. O número de ninhos hospedeiros é fixados, e o ovo colocado pelo cuco pode ser descoberto pela ave hospedeira com a probabilidade de $p_a \in [0, 1]$. Quando isso ocorre, a ave hospedeira pode se livrar do ovo ou simplesmente abandonar o ninho completo e construir um novo em outro local.

Para um problema de maximização, a qualidade de uma solução é diretamente proporcional ao valor da função objetivo, e para um problema de minimização é inversamente proporcional. Para simplificar o ponto de vista de implementação, cada ovo em um ninho representa uma solução e cada cuco pode colocar somente um ovo (representando assim uma solução). Logo o objetivo é utilizar novas e melhores soluções em potencial (cucos) para substituir uma solução não tão boa no ninho. Neste caso, não existe distinção entre ovo, ninho e cuco.

O ponto-chave do algoritmo é balancear combinações de uma caminhada aleatória local e uma caminhada aleatória explorativa global. Essa caminhada aleatória global é feita utilizando o voo de Lévy, e é uma cadeia de Markov cujo próximo passo/localização depende somente da localização atual (primeiro termo da equação (2.1)) e a probabilidade de transição (segundo termo).

$$x_i^{t+1} = x_i^t + \alpha \mathbf{L}(s, \lambda) \quad (2.1)$$

Onde,

$$\mathbf{L}(s, \lambda) = \frac{\lambda \Gamma(\lambda) \sin(\frac{\pi\lambda}{2})}{\pi} \frac{1}{s^{1+\lambda}} \quad (2.2)$$

x_i^{t+1} , é a solução atual, e x_i^t é a solução anterior.

O valor de $\alpha > 0$, é o fator de escala do tamanho do passo, que é geralmente relacionado à escala do problema de interesse. Logo, a Equação 2.2 é uma equação estocástica para uma caminhada aleatória.

Um voo de Lévy é uma caminhada aleatória em que o tamanho dos passos tem uma distribuição de probabilidade, com as direções dos passos sendo isotrópicos e aleatórios. Com uma aproximação proposta por Mantegna (MANTEGNA; STANLEY, 1994) que gera números aleatórios seguindo o padrão de distribuição do voo de Lévy. A recomendação de Mantegna é usar duas variáveis estocásticas para desenhar uma distribuição a partir de uma distribuição normal $[0,1]$:

$$\lambda = \frac{u}{|v|^{\frac{1}{\lambda}}} \quad (2.3)$$

$$u \sim N(0, \sigma_u^2)$$

$$v \sim N(0, \sigma_v^2)$$

As variáveis estocásticas são u e v , e possuem desvio padrão dado pela Equação 2.4. Onde, $\Gamma()$ denota a função gamma (Equação 2.5) que aumenta rapidamente para argumentos positivos. E a integral produzirá resultados analíticos do lado direito do plano complexo. Para a aplicação em algoritmos de otimização a função gamma possuirá somente valores positivos, respeitando assim o espaço de busca, onde os valores de x devem ser reais.

$$\sigma_u(\lambda) = \left[\frac{\Gamma(1 + \lambda) \sin\left(\frac{\pi\lambda}{2}\right)}{\Gamma\left(\frac{1+\lambda}{2}\right) \lambda 2^{\frac{\lambda-1}{2}}} \right] \quad (2.4)$$

$$\text{e } \sigma_v(\lambda) = 1 \text{ para } \lambda = 1, 5$$

$$\Gamma(x) = \int_0^{\infty} e^{-t} t^{x-1} dt \quad (2.5)$$

O CS padrão pode então ser estruturado no pseudo algoritmo 1.

2.5 Algoritmo *Discrete Cuckoo Search* (DCS)

O algoritmo *Discrete Cuckoo Search* é uma versão adaptada do algoritmo CS, tendo o principal propósito otimizar problemas combinatoriais (OUAARAB, 2014). Nessa adaptação, um ovo representa uma solução em um espaço combinatorial que pode ser mostrado como uma permutação. Logo, o espaço de busca, é composta por um conjunto

Algorithm 1 Cuckoo Search (CS)

```

1: Define a Função Objetivo  $f(x)x = (x_1, , x_d)^T$ 
2: Gera a população inicial de n ninhos hospedeiros  $x_i(1, 2, , n)$ 
3: while (critério de parada) do
4:   Pega um cuco aleatoriamente pelo voo de Lévy, Avaliar a qualidade/fitness  $F_i$ 
5:   Pegar um ninho aleatoriamente entre n, e chamar de  $j$ 
6:   if  $F_i > F_j$  then
7:     então atualiza  $F_j$  como nova solução
8:   end if
9:   Uma fração ( $Pa$ ) dos piores ninhos são abandonados e novos são gerados
10:  Ranquear os ninhos e encontrar a melhor solução atual
11: end while

```

de permutações. Um ovo é gerado realizando um LF (*Lévy Fligth*), começando em uma posição de um ovo escolhida aleatoriamente. Se o valor encontrado pela função objetivo for melhor nesta posição encontrada aleatoriamente, então o ovo é movido para esta nova posição. O movimento no espaço de busca é definido pela distância entre as soluções vizinhas que leva a definir operadores e perturbações conforme o problema estudado.

Logo, o tamanho do passo α é definido pela distância entre duas soluções no espaço de busca. A distância pode ser calculada de duas formas, a primeira é a *Euclidiana* e a segunda é a distância de *Hamming*.

1. Distância *Euclidiana*:

A distância *Euclidiana* é a distância geométrica no espaço multidimensional, calculada a partir de $d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$.

2. Distância de *Hamming*:

A distância de *Hamming* entre duas permutações é o número de elementos não correspondentes na sequência. Por exemplo (Figura 11):

P1	2	2	3	2	3	4	5	6
P2	2	2	1	1	5	4	5	6

Figura 11 – Distância de *Hamming* entre dois vetores.

A distância de *Hamming* entre $H(P_1, P_2) = 3$ (destacado em vermelho), ou seja, somente as duas primeiras posições e as três últimas possuem o mesmo elemento.

Dessa forma o tamanho do passo, pode ser adaptada (Equação 2.6). Onde “**D**” é a distância de *Hamming* de dois vetores soluções, é definida pela distância entre a permutação de suas sequências. Esse movimento (permutação) cria novas soluções, em outras

palavras, para uma permutação chegar mais próxima a outra permutação, a quantidade de seus elementos comuns tem que aumentar (Figura 12). As lacunas $P_{(1 \rightarrow 2)}$ deve ser preenchida em relação à distância anterior das permutações, e podem ser preenchidas com elementos de P_1 ou P_2 . Neste exemplo as lacunas então foram preenchidas com $P_1(3)$, $P_2(1)$ e $P_1(3)$ formando assim um vetor completo (Figura 13).

\mathbf{D} é a distância de *Hamming* de dois vetores soluções, é definida pela distância entre a permutação de suas sequências. Esse movimento (permutação) cria novas soluções, em outras palavras, para uma permutação chegar mais próxima a outra permutação, a quantidade de seus elementos comuns tem que aumentar (Figura 12). As lacunas $P_{(1 \rightarrow 2)}$ deve ser preenchida em relação à distância anterior das permutações, e podem ser preenchidas com elementos de P_1 ou P_2 . Neste exemplo as lacunas então foram preenchidas com $P_1(3)$, $P_2(1)$ e $P_1(3)$ formando assim um vetor completo (Figura 13).

$$h = [\alpha \mathbf{D} \text{Lévy}(\lambda)] \tag{2.6}$$

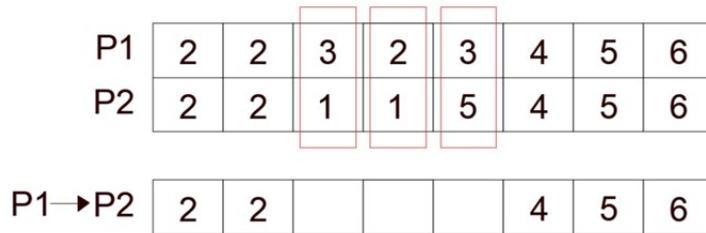


Figura 12 – Lacunas geradas pela distância de *Hamming*.

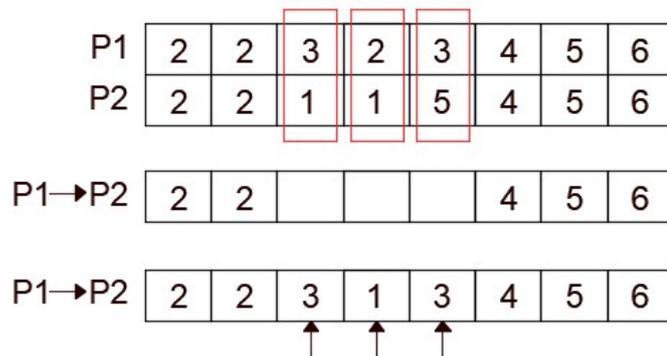


Figura 13 – Lacunas preenchidas.

2.6 Algoritmo Busca Cuco Discreta Híbrido com o Algoritmo Genético (DCS-GA)

O motivo inicial para se mesclar dois algoritmos é para combinar as vantagens de ambos os algoritmos. Em (KANAGARAJ; PONNAMBALAM; JAWAHAR, 2013a),

propõe utilizar o algoritmo *Cuckoo Search* híbrido com o *Genetic Algorithm*, ambos algoritmos baseado em população, utilizando o GA para a geração da população inicial (de forma aleatória) e o uso do CS para aumentar a performance da exploração de novas soluções no espaço para novas gerações através do processo de reprodução (*crossover* e mutação).

Neste trabalho, o processo é inverso, é utilizado o algoritmo DCS para a construção das soluções iniciais, e utilizando a performance de *Lévy Flight* para construção de novas soluções, aumentando o espaço de busca para exploração, logo após, utiliza-se o GA para carregar essas soluções para as próximas gerações, utilizando o processo de reprodução (*crossover* e mutação), para trabalhar com somente boas soluções, é adotado também o elitismo.

3 METODOLOGIA PROPOSTA PARA A OTIMIZAÇÃO DO *DESIGN* DE REDES DE FIBRA ÓPTICA

Este Capítulo mostra que para se projetar uma rede utiliza-se um conjunto de matrizes (Seção 3.1). Essas matrizes são constituídas de variáveis de restrições impostas pelo sistema de comunicação, compostas de valores reais, como as demandas em que cada cidade dispõe, dadas em Gbit/s (Giga bit por segundo), o tamanho do *link*, medido em km e o custo da rede, que se encontra em unidade adimensional (Seção 3.2).

3.1 Modelagem da Rede

A interconexão entre no mínimo dois pontos finais de comunicação pode formar/constituir uma rede e as suas propriedades subjacentes podem afetar muito seu valor. Uma rede pode ser definida como um grafo onde os vértices são os nós (origem/destino) e os arcos são os *links* que ligam esses nós, por onde todas as demandas escoam (Figura 14). A forma que a demanda é tratada no processo de modelagem é representada na formulação arco-caminho (como dito no capítulo anterior).

Cada nó é caracterizado por um número $[i]$, na rede da (Figura 14) identifica-se quatro nós e seis *links*, por onde a toda a demanda escoar. Os nós são os pontos em que os equipamentos geradores de demanda estão alocados e onde os usuários da rede estão. As demandas previstas devem ser especificadas, no caso da rede OTN/WDM essa especificação é em Gbit/s, e é modelada do nó de origem somado a um ou mais nós de destino. Na rede exemplo estão indicadas duas demandas previstas:

1. *dem1*: É a demanda prevista para ser atendida entre o nó de origem 3 e o nó de destino 2;
2. *dem2*: É a demanda prevista para ser atendida entre o nó de origem 4 e o nó de destino 2.

As necessidades da rede devem ser atendidas, para isso os *links* são os caminhos para escoar as demandas para os seus respectivos nós. A nomenclatura apontada na Figura 14 indica um nome e um índice, por exemplo, o *link3*, identifica o *link* que liga o nó 3 (N3) e o nó 4 (N4). A capacidade total de cada *link*, caracterizada pela capacidade dos equipamentos de transmissão alocados, deve ser capaz de atender o fluxo de demanda

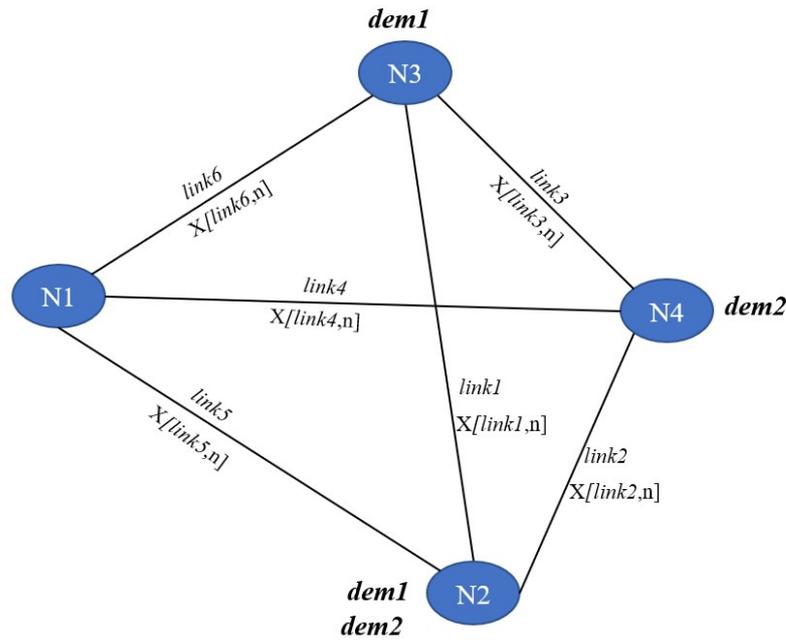


Figura 14 – Representação da Rede

escolhido para ser escoado por aquele *link*. A variável $X_{((\text{link}3, n))}$, de característica binária, é responsável pela alocação e escolha da capacidade de cada *link*, essa variável representa a escolha (ou não) de um sistema de transmissão de modularidade $[n]$ para ser alocado no *link3*.

Tendo em mente essas definições, pode-se então explicar o “caminho”. O caminho, nada mais é do que, o conjunto de percursos em sequência que as demandas utilizam para ser escoadas de suas origens até os seus destinos. A alocação de caminho para o escoamento das demandas é feita conforme o modelo MILP da Seção 3.2.

Para cada demanda prevista entre dois nós existe um conjunto de caminho que pode ser utilizado. Para o exemplo da Figura 14 a Tabela 1 apresenta os possíveis caminhos das demandas previstas (*dem1* e *dem2*) são propostos.

Demanda	Origem	Destino	Caminho	Links
<i>dem1</i>	N3	N2	k_1	<i>link1</i>
			k_2	<i>link6</i> → <i>link5</i>
			k_3	<i>link3</i> → <i>link2</i>
<i>dem2</i>	N4		k_1	<i>link2</i>
			k_4	<i>link4</i> → <i>link5</i>
			k_3	<i>link3</i> → <i>link1</i>

Tabela 1 – Escoamento de demanda.

Uma nova variável representa o caminho que a demanda pode ser escoada (k_1), essa variável vem do algoritmo *k*-caminho, para esse exemplo, significa que o algoritmo

apresentará três caminhos mais curtos entre o nó de origem e o nó de destino. Simplificando a configuração de atendimento para cada demanda prevista:

Um único caminho pode ser utilizado para atender a uma demanda. Por exemplo, a demanda *dem1* pode ser totalmente atendida por k_1 , k_2 ou k_3 ;

Essa possibilidade vêm da variável de decisão $Y_{([caminho,demanda])}$, ela especifica qual parcela da demanda (*dem1*, por exemplo) vai ser escoado pelo caminho (k_1 , por exemplo).

3.2 Formulação do Problema

O problema do *design* de rede de fibra óptica para rede OTN/DWDM é estudado, o objetivo é minimizar o custo total da rede para a transmissão de várias taxas de dados. Outros custos como, *switches*, multiplexadores, amplificadores entre outros não são considerados. O modelo matemático aqui proposto é o MILP. A equação 3.1 traz a função objetivo responsável pelo custo do sistema. O custo é calculado somando-se os custos dos sistemas de transmissão óptica escolhidos para o escoamento da demanda entre os nós.

$$Min \sum_{[i] \in LINK} \sum_{[n] \in OLINK} C_{[i][n]} X_{[i][n]} \quad (3.1)$$

O produto da função objetivo contabiliza o custo quando a variável $X_{[i][n]}$ assume valor 1 (um).

Notação:

LINK: Conjunto formado por todas as arestas da rede, usados para ligar as demandas dos vértices.

O_{LINK} : Conjunto de capacidade, $[n]$, (40, 100 e 400 Gbit/s), dos sistemas de transmissão óptica OTN/WDM candidatas nos *links* $[i] \in LINK$.

$C_{[i][n]}$: Custo do sistema de transmissão óptica OTN/WDM possuindo a capacidade (em Gbit/s) $[n] \in O_{LINK}$ no *link* $[i] \in LINK$.

$X_{[i][n]}$: Variável que representa se o *link* $[i]$ de capacidade $[n]$ é ou não escolhido para ser alocado. O seu valor é binário (0 ou 1).

Antes de se aplicar a função objetivo ao problema de interesse, um conjunto de restrições de balança de demanda deve ser atendida, conforme a Equação 3.2.

$$\sum_{[n] \in OLINK} Cap_{[n]} X_{[i][n]} - \sum_{[k] \in \Omega_i} Y_{[j][k]} \geq 0, \forall [i] \in LINK \quad (3.2)$$

Notação:

$dem_{[j]}$: Demanda $[j] \in DEM$ prevista, em Gbit/s, para atender a demanda da rede entre um vértice de origem e possíveis vértices de destinos (TN). Essa demanda pode ser representada em termos de taxa de transmissão ou quantidade de serviço modular padrão.

$Cap_{[n]}$: Capacidade (em Gbit/s) $[n]$, dos sistemas de transmissão OTN/WDM candidatos.

$Y_{[j][k]}$: Variável que representa a demanda $[j] \in DEM$, sendo atendida pelo caminho $[k] \in P_j$. Dependendo da forma a qual foi modelada, pode assumir valor real ou binário. A forma que é representada exige a condição da avaliação de cenários, se existirá ou não exclusividade na alocação de caminhos para o escoamento da demanda prevista.

Ω_i : Conjunto formado pelos caminhos que precisam utilizar o *link* $[i]$ para escoar o seu fluxo de demanda.

TN: Conjunto formado por possíveis vértices de destino para cada demanda da rede. Dessa forma, pode-se avaliar situações em que um vértice de origem pode ter a demanda atendida por mais de um vértice de destino. O sistema é então restringido para um conjunto de k -caminhos, que um vértice de origem pode chegar a um vértice de destino.

DEM: Conjunto composto por todas as demandas previstas (em Gbit/s) para serem atendidas pela rede. A matriz de demanda possui vários vértices de origem e apenas dois de destinos. Logo, o tráfego deve ser escoado de forma exclusiva e complementar.

k_d : Conjunto de caminhos a atender a demanda $[d] \in DEM$. Dentro deste conjunto contem caminhos que possibilita o fluxo de demanda $[d]$ para $[t] \in TN$ possíveis vértices de destino.

Nas Equações 3.3 e 3.4 estão as variáveis mais importantes de toda a formulação, nelas estão contidas informações da rede a ser modelada. A Equação 3.3, por exemplo, garante que o somatório dos fluxos de demanda dos caminhos candidatos para atender uma determinada demanda seja igual ao valor previsto para essa demanda e para evitar buscas desnecessários por caminhos ineficazes. A equação 3.4 é realizada para assegurar que apenas um sistema de transmissão óptica deve ser alocado em cada *link*, assim consegue-se trabalhar com o ganho de escala praticado no mercado, impedindo buscas desnecessárias por soluções que utilizem *links* paralelos.

$$\sum_{[k] \in P_j} Y_{[j][k]} = dem_{[j]}, \forall [k] \in DEM \quad (3.3)$$

$$\sum_{[n] \in OLINK} X_{[j][k]} \leq 1, \forall [i] \in LINK \quad (3.4)$$

3.3 DCS para Otimizar a Rede OTN/WDM

O fluxograma desenvolvido na Figura 15 apresenta as principais rotinas do CS: inicialização da população de ninhos, avaliação da função objetivo, *ranking* e gera uma nova solução por voo de Lévy. Vale lembrar que essa nova solução gerada pelo voo de Lévy é formada a partir de movimentos a partir da distância de *Hamming*.

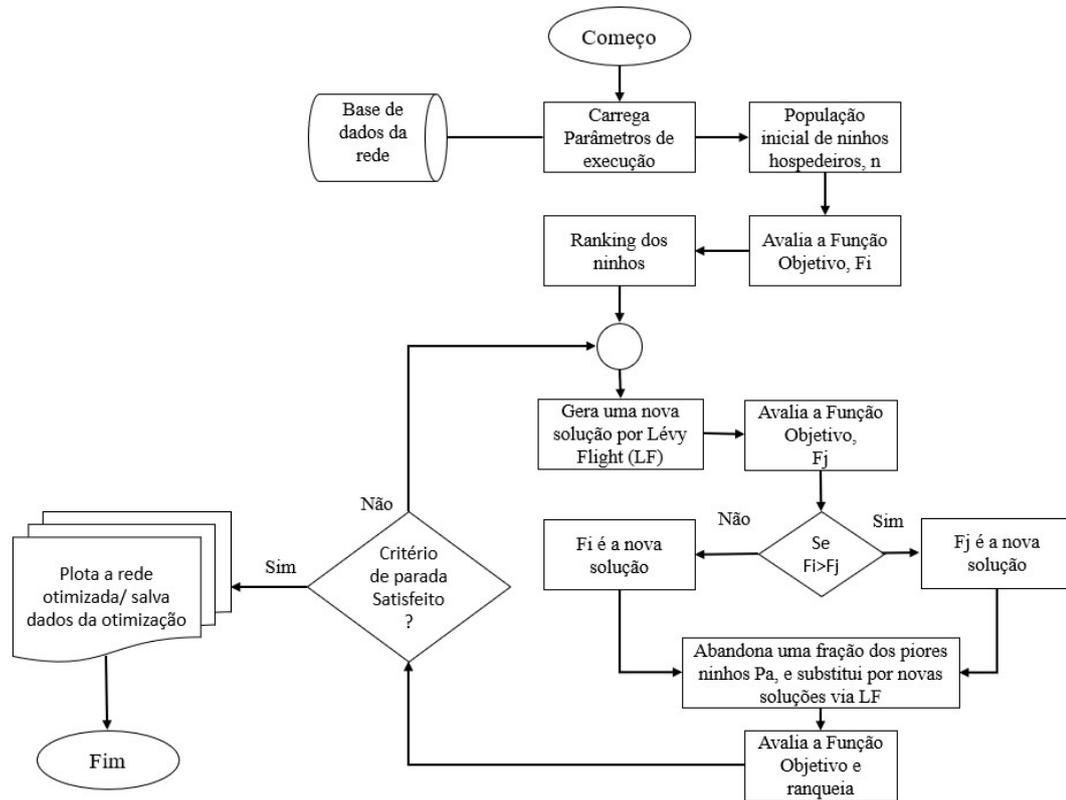


Figura 15 – Fluxograma do DCS para a otimização da rede óptica.

Como citado na seção 3.2 as variáveis X e Y são as mais importantes, pois elas contêm informações da base de dados e a partir delas é desenvolvida a população inicial, da mesma forma como no algoritmo contínuo, a população inicial é feita de forma aleatória. O pseudocódigo do DCS está estruturado abaixo.

Existem quatro estágios principais do Algoritmo DCS, nomeadamente, população inicial, *getcuckoo*, *newnest* e *emptynest* e serão descritos os métodos utilizados ao longo desses estágios.

3.3.1 População inicial

Para gerar a população inicial a quantidade de ninho “ n ” é escolhida pelo usuário. A codificação do indivíduo é através de duas etapas. A rede da Figura 14 vai ser novamente utilizada para a compreensão da formação da população inicial. A rede agora contém três

Algorithm 2 Discrete Cuckoo Search - DCS

-
- 1: Inicializa os parâmetros do algoritmo
 - 2: Define o número de ninhos (n)
 - 3: Define o número de geração ($nGer$)
 - 4: Define a probabilidade de descoberta (P_a)
 - 5: Define $\lambda \leftarrow 3/2$
 - 6: Define $\alpha \leftarrow 0,01$
 - 7: Define a Função Objetivo $f(x), x = (x_1, \dots, x_d)^T$
 - 8: Gera a população inicial de n ninhos hospedeiros $x_i (i = 1, 2, \dots, n)$
 - 9: Avalia a qualidade de $f(x_i)$
 - 10: Ranqueia os ninhos e encontra a melhor solução atual
 - 11: **while** ($t < nGer$) **do**
 - 12: Gera uma nova solução:
 - 13: Etapa *getcuckoo*:
 - 14: Calcular a distância \mathbf{D} (*Hamming*) entre um ninho presente e o melhor ninho
 - 15: Calcular o passo do voo de Lévy usando $Lvy(\lambda)$ com a Equação 2.2 e Equação 2.4
 - 16: Calcular o tamanho do passo h com 2.6
 - 17: **Fim** da etapa *getcuckoo*
 - 18: Etapa *newnest*:
 - 19: Em (ROMERO; MANTOVANI, 2004) aplica-se o operador *swap move* para obter novas soluções como $x_i^{(t+1)} = F_{swap}(x_i^t, h)$
 - 20: **Fim** da etapa *newnest*
 - 21: Pegar um ninho aleatoriamente entre n , e chamar de j
 - 22: **if** ($F_i > F_j$) **then**
 - 23: então atualiza F_j como nova solução
 - 24: **end if**
 - 25: Etapa *emptynest* Uma fração (P_a) dos piores ninhos são abandonados e novos são gerados
 - 26: Manter os melhores ninhos com qualidade de soluções
 - 27: **Fim** da etapa *emptynest*
 - 28: Ranquear os ninhos e encontrar a melhor solução global
 - 29: **end while**
-

nós de origem (N1, N2 e N3) e um único nó de destino (N4) para as demandas (Figura 16).

Utilizando a Configuração 01, citado na seção 3.1, a rede da Figura 16 dispõe de seis *links* para escoar a demanda de três nós de origem (N1, N2 e N3) para o nó de destino (N4). Os valores de demanda usadas, neste exemplo, são números arbitrários e medidos em Gbit/s.

1. Criação da variável Y : Um vetor de codificação representa um percurso em que a demanda de dado sai do nó de origem chegando ao nó de destino, na sequência que se encontra na codificação. O vetor de codificação armazena a demanda que passa em cada arco do grafo. Nessa etapa os valores de demanda (contida na base de dados) é alocada (de forma aleatória) nos possíveis caminhos a serem escoadas.

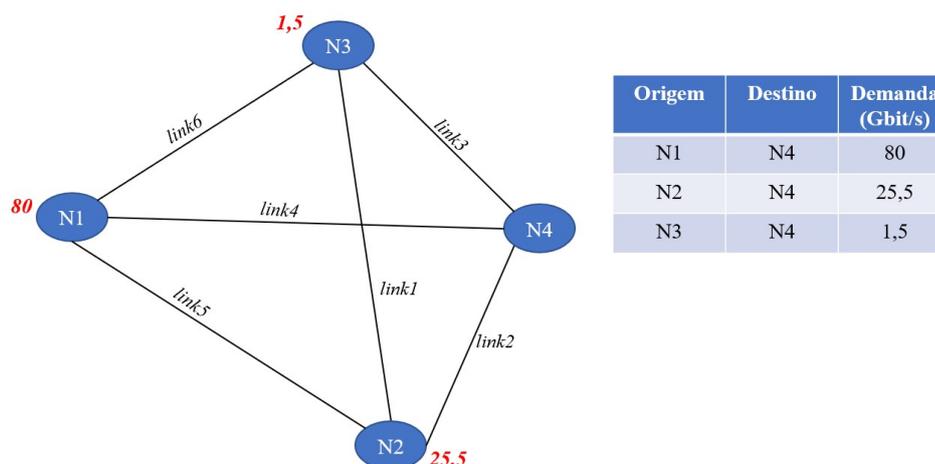


Figura 16 – Rede com três nós de origem (N1, N2 e N3) e um nó de destino (N4).

Assim a variável Y representa uma matriz com múltiplas possíveis soluções (Figura 17). Antes de avançar para as demais etapas, a factibilidade de uma solução deve ser analisada, ou seja, o fluxo total a ser escoado através de cada *link* pode ser verificado e não deve ultrapassar 400 Gbit/s;

2. Criação da variável X : Essa etapa ocorre sempre após a criação da variável Y . Depois das demandas alocadas nos arcos, suas respectivas modularidades são dispostas, sempre maior ou igual a demanda daquele arco. Como o problema de interesse é uma rede OTN/WDM as possíveis modularidades são [40 100 400] Gbit/s. Para isso a codificação da variável X é binária, quando o fluxo no *link* é nulo a variável X é configurada como 0, caso contrário é configurada como 1 (Figura 18). Na Figura 19 está representada as três primeiras topologias de caminhos da matriz Y (Figura 17, em cada topologia resultante contém o *link* utilizado, a real demanda que fluirá pelo *link* e sua respectiva modularidade. Na variável X o valor de $k_1 = 011100$, pois, apenas o *link2*, *link3* e *link4* são utilizados.

Após a variável X formada, utiliza a função objetivo da Equação 3.1 para calcular o custo de cada possível solução.

3.3.2 Ranking de Soluções

A população inicial pode então ser caracterizado por um conjunto de soluções factíveis para o problema apresentado. Após ter calculado o custo da solução o conjunto de soluções é então avaliado, quanto menor o custo melhor o indivíduo.

link1	link2	link3	link4	link5	link6	
0	25,5	1,5	80	0	0	Caminho 1: k_1

Uma única solução

link1	link2	link3	link4	link5	link6	
0	25,5	1,5	80	0	0	Caminho 1: k_1
0	25,5	81,5	0	0	80	Caminho 2: k_2
1,5	107	0	0	80	0	Caminho 3: k_3
·	·	·	·	·	·	Caminho n: k_n

População de soluções

Figura 17 – Representação de uma única solução e de múltiplas possíveis soluções da matriz Y.

	link1	link2	link3	link4	link5	link6	
Etapa Y	0	25,5	1,5	80	0	0	Caminho 1: k_1
Etapa X	0	40	40	100	0	0	Caminho 1: k_1
				↓			
Etapa X	0	1	1	1	0	0	Caminho 1: k_1

Figura 18 – Etapa Y e X.

3.3.3 Estágio *Getcuckoo*

Posterior a criação da população inicial, para cada indivíduo é avaliada a qualidade com a Função Objetivo 3.1, vale frisar que quanto menor o custo melhor o indivíduo. Para a codificação utilizada em que os arcos são ordenados em um arranjo vetorial, as propostas para representar estruturas vizinhas ou caracterização de vizinhança é a permutação das demandas dentro do espaço de caminhos, ou seja, se uma rede é infactível o que se altera é o caminho em que a demanda irá percorrer e não o valor da demanda. Essa permutação pode ocorrer de três formas: i) duas permutações de posição no arranjo vetorial; ii) uma troca de posição ou iii) várias trocas de posições (ROMERO; MANTOVANI, 2004).

Então duas matrizes são criadas para o estágio *getcuckoo*, uma matriz com todos os indivíduos do menor para o maior (custo), chamada de “i” e outra com ordem aleatória,

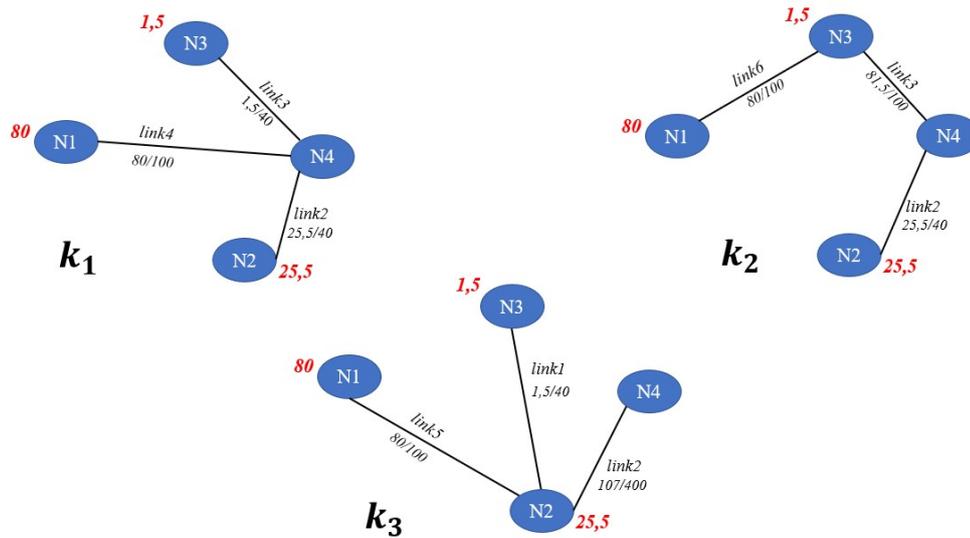


Figura 19 – Representação gráfica de três possíveis soluções.

chamada de “ j ”. O primeiro elemento da matriz “ i ” é comparado ao primeiro elemento da matriz “ j ”, essa comparação é feita a partir da distância de *Hamming*, ou seja, se a distância for maior que zero, significa que existem elementos diferentes. Logo o elemento j será movido para próximo ao i , em outras palavras, os elementos diferentes irão diminuir. Esse procedimento é então repetido para todos os elementos de i e j .

Qualquer alteração a se fazer nas soluções ocorrem na variável Y . A Figura 20 traz um exemplo simples de como a etapa *getcuckoo* ocorre, um vetor com uma única solução está representado por Y_i neste contexto uma demanda deve ser escoada de três nós de origem para o nó de destino. Outro vetor solução é escolhido aleatoriamente e é chamado de Y_j , a distância de *Hamming* é $D_{ij} = 2$, pois dois elementos desses vetores são diferentes (*link1* e *link4*). Um novo vetor é criado mantendo os valores dos elementos iguais, e os elementos diferentes permanecem com lacunas, a forma que essas lacunas são preenchidas vai depender da probabilidade expressa em h , salientando que h depende da distância de *Hamming* e do valor de Lévy. Um número aleatório é gerado e se esse número for $\leq h$ então as lacunas são preenchidas por Y_i , caso contrário são preenchidas por Y_j . No exemplo, as lacunas foram preenchidas por Y_j .

3.3.4 Estágio *Newnest*

A solução resultante da etapa *getcuckoo* passa pela etapa *newnest* para aumentar a diversidade e a probabilidade de encontrar soluções melhores. Usando a função *randperm* do Matlab é possível obter permutações aleatórias do vetor de solução e o número de permutações é definido pelo usuário, no exemplo da Figura 21 o número de permutações (nPermuta) foi igual a dois.

Assim as demandas que antes escoavam pelo *link2* e *link6* passam agora a ser esco-

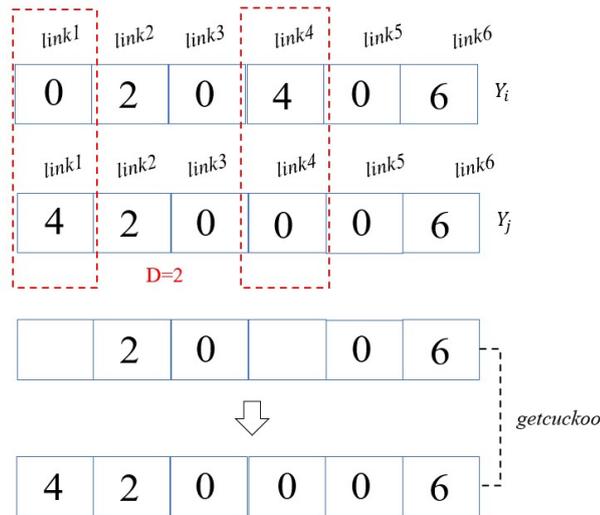


Figura 20 – Etapa *getcuckoo*

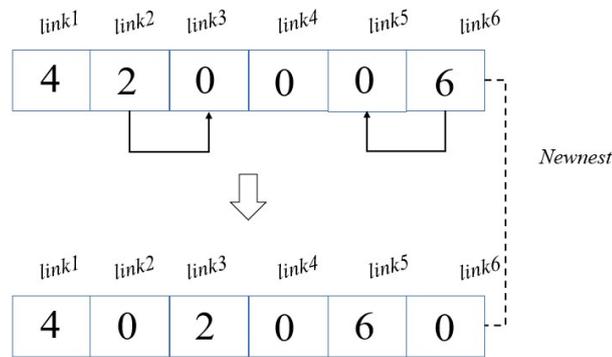


Figura 21 – Etapa *newnest*

adas pelo *link3* e *link5* respectivamente. O que significa que o que é alterado é o caminho e não os valores das demandas. Deste modo o estágio de *newnest* é finalizado. E novamente a factibilidade e o fluxo de cada *link* é avaliado e suas respectivas modularidades são alocadas (variável X), se uma solução é infactível a etapa *getcuckoo* e *newnest* são realizados novamente, até criação de uma solução factível ser formada. Posteriormente o custo é calculado e o processo de ranquear as soluções é realizado.

3.3.5 Estágio *Emptynest*

O estágio *emptynest* é importante pela caracterização do algoritmo Busca Cuco, com esse passo existe mais uma probabilidade de gerar soluções aumentando ainda mais a diversidade. A probabilidade de descoberta (P_a) é definida pelo usuário, um número aleatório é gerado, se $rand() \leq P_a$ então os melhores indivíduos são novamente alterados na tentativa de se conseguir uma solução melhor, caso a nova solução seja melhor a variável Y é atualizada caso contrário a variável Y permanece a mesma. O critério de parada é o número de gerações, após seja alcançada a melhor solução (menor custo) a rede é plotada.

3.4 Algoritmo DCS híbrido com GA (DCS-GA) para Otimizar a Rede OTN/WDM

Um algoritmo híbrido é proposto para mesclar características distintas que possam contribuir em conjunto para um novo algoritmo mais potente. Encontrar uma solução ótima para um problema de otimização é muitas vezes uma tarefa muito desafiadora, dependendo da escolha e do uso correto da técnica de otimização. Em geral, uma técnica global ideal de otimização deve ter as seguintes características (KANAGARAJ; PONNAMBALAM; JAWAHAR, 2013b):

1. O método deve ser simples e fácil de implementar;
2. Deve existir um bom equilíbrio entre exploration e exploitation;
3. Deve convergir rápido;
4. O algoritmo deve conter o mínimo de parâmetros para controlar;
5. O algoritmo deve exigir pouco esforço computacional.

O algoritmo busca cuco vem sendo fortemente mesclado com outras metaheurísticas para solucionar diversos tipos de problema, como por exemplo com o algoritmo PSO (*Particle Swarm Optimization*) (BABUKARTIK; DHAVACHELVAN, 2012), com ACO (*Ant Colony Optimization*) (WANG *et al.*, 2011), com algoritmo genético (DAOUD, 2013), com algoritmo Lobo (LONG *et al.*, 2020), com algoritmo SA (*Simulated Annealing*) (ALKHATEEB; ABED-ALGUNI, 2019), etc.

Neste trabalho o algoritmo busca cuco discreto é considerado uma metaheurística mestre que vai coordenar todo o processo de busca e o algoritmo genético é o subordinado. O funcionamento é básico, após encontrar a melhor solução na Seção 3.3 é executado a etapa de *crossover* e mutação. Com isso um novo fluxograma de funcionamento é apresentado na Figura 22 e suas principais terminologias podem ser consultada na Tabela 2.

Competências	Termos equivalentes no DCS-GA
População	Número de ninhos hospedeiros
Solução	Cuco = Ovo em um ninho
Tamanho da população	Fixado
Novas soluções	Ovo da ave cuco
<i>Fitness</i>	Qualidade dos ovos
Espaço de busca	Posição dos ninhos

Tabela 2 – Terminologia equivalente usada no DCS-GA.

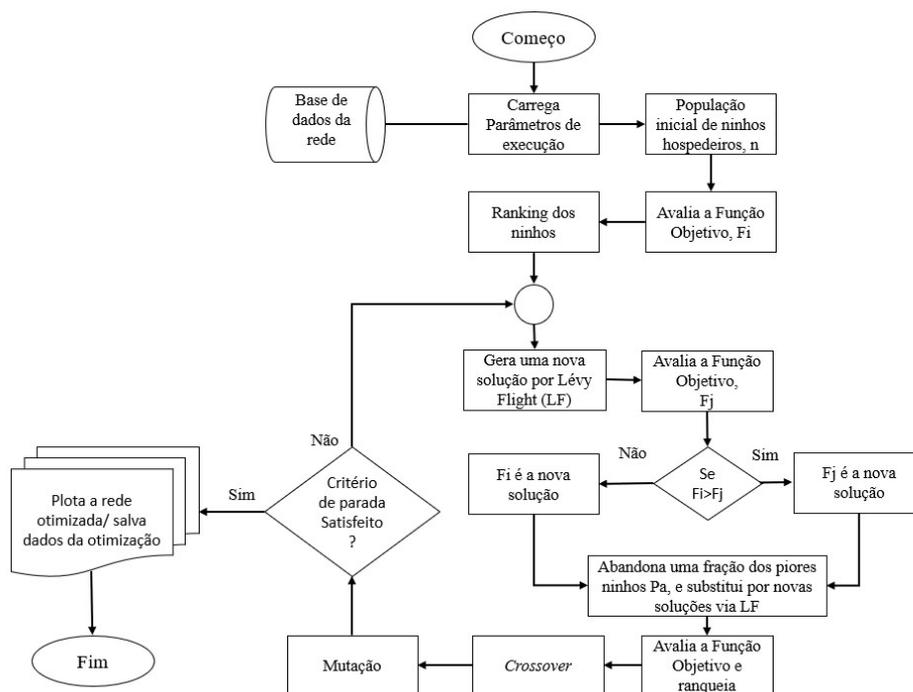


Figura 22 – Fluxograma DCS-GA.

No algoritmo híbrido as probabilidades de mutação e *crossover* são de 100% e para isso os dois melhores indivíduos são selecionados (menores custos). O pseudocódigo do algoritmo DCS-GA pode então ser estruturado:

3.4.1 *Crossover*

Após selecionado os dois melhores indivíduos (PAI I e PAI II), são realizadas a troca de informações para possíveis melhores soluções serem encontradas ao decorrer das gerações (FILHO I e FILHO II). O cruzamento ocorre na etapa Y (Figura 23a), para se evitar uma demanda duplicada a restrição de que caminhos de uma mesma demanda não podem ser separados por este ponto de corte, isso resultaria um indivíduo inactivél. O número de demanda a ser escoada na rede é o fator que limita os pontos de corte, assim respeitando a quantidade de caminhos candidatos para cada demanda.

Cada filho (solução) gerado na etapa Y é passado para etapa X para avaliar a qualidade. Somente um filho poderá continuar na próxima geração, e possui os seguintes critérios:

1. Quando o *crossover* resulta em duas soluções factíveis: o filho de melhor qualidade (menor custo) irá constituir a próxima geração;
2. Quando o *crossover* resulta em uma solução factível: o filho factível é selecionado;

Algorithm 3 DCS-GA

```

1: Inicializa os parâmetros do algoritmo
2: Define o número de ninhos ( $n$ )
3: Define o número de geração ( $nGer$ )
4: Define a probabilidade de descoberta ( $P_a$ )
5: Define  $\lambda \leftarrow 3/2$ 
6: Define  $\alpha \leftarrow 0,01$ 
7: Define a Função Objetivo  $f(x), x = (x_1, \dots, x_d)^T$ 
8: Gera a população inicial de  $n$  ninhos hospedeiros  $x_i (i = 1, 2, \dots, n)$ 
9: Avalia a qualidade de  $f(x_i)$ 
10: Ranqueia os ninhos e encontra a melhor solução atual
11: while ( $t < nGer$ ) do
12:   Gera uma nova solução:
13:   Etapa getcuckoo:
14:     Calcular a distância  $\mathbf{D}$  (Hamming) entre um ninho presente e o melhor ninho
15:     Calcular o passo do voo de Lévy usando  $Lvy(\lambda)$  com a Equação 2.2 e Equação 2.4
16:     Calcular o tamanho do passo  $h$  com 2.6
17:     Fim da etapa getcuckoo
18:     Etapa newnest:
19:     Em (ROMERO; MANTOVANI, 2004) aplica-se o operador swap move para obter
    novas soluções
20:     como  $x_i^{(t+1)} = F_{swap}(x_i^t, h)$ 
21:
22:     Fim da etapa newnest
23:
24:     Pegar um ninho aleatoriamente entre  $n$ , e chamar de  $j$ 
25:
26:     if ( $F_i > F_j$ ) then
27:       então atualiza  $F_j$  como nova solução
28:     end if
29:     Etapa emptynest
30:
31:     Uma fração ( $P_a$ ) dos piores ninhos são abandonados e novos são gerados.
32:     Manter os melhores ninhos com qualidade de soluções
33:     Fim da etapa
34:     emptynest
35:     Etapa Algoritmo genético
36:     Ranquear os indivíduos e encontrar duas melhores soluções atual
37:     Executar o crossover nas duas melhores soluções
38:     Executar o mecanismo de mutação
39: end while

```

- Quando o *crossover* resulta em nenhuma solução factível: Realiza novamente o *crossover* com outros pontos de corte, até encontrar um Filho factível.

Para o operador *crossover* acontecer a probabilidade (fornecida pelo usuário) deve ser atendida. Quando não é atendida o indivíduo Pai é mantido para a próxima geração.

3.4.2 Mutação

Os indivíduos gerados pelo *crossover* sofrem leve alterações (aleatórias) nos caminhos escolhidos para escoar cada demanda. A probabilidade de mutação também é fornecida pelo usuário, e nem todos os indivíduos sofrem com mutação.

A mutação também ocorre na etapa Y, e por consequência a etapa X é executada para que a nova modularidade possa ser ajustada. A Figura 23b mostra como a mutação ocorre, onde a demanda do *link3* passa agora a ser escoada pelo *link4*.

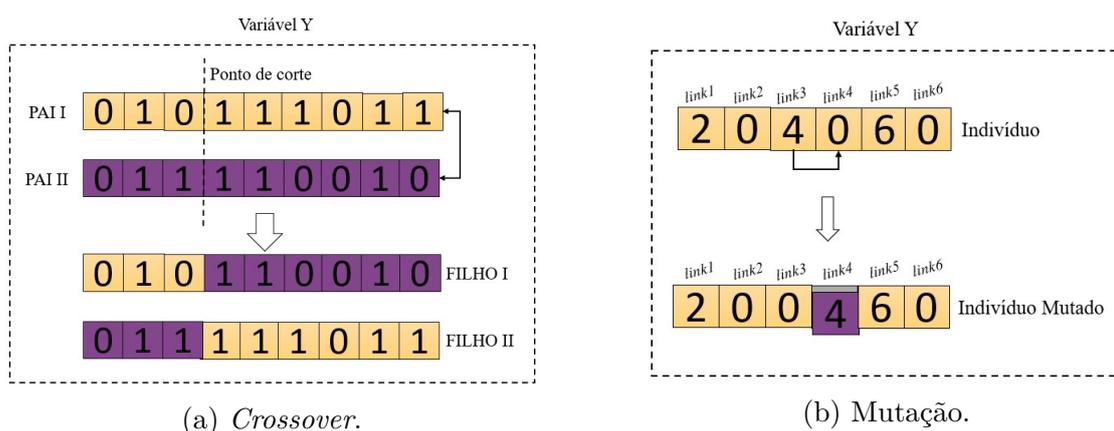


Figura 23 – *Crossover* e *Mutação*.

A operação de mutação evita que haja uma convergência prematura, assim possibilitando uma diversidade na população no decorrer das gerações.

4 RESULTADOS

Neste capítulo é apresentado o sistema desenvolvido, o problema considerado para teste, para validar o método proposto e os resultados obtidos. A metodologia resultante pode ser utilizada em redes de diferentes níveis hierárquicos e diferentes tecnologias de transmissão. O que deve ser atualizado/alterado são os dados de entrada, por exemplo, a quantidade de nós, de demanda, o custo de equipamento e do *link* de cada tecnologia, etc. O núcleo do sistema é a implementação do algoritmo busca cuco discreta e algoritmo busca cuco discreta híbrida com o algoritmo genético para resolver o problema do design de rede de fibra óptica, conforme discutido em capítulos anteriores.

4.1 Problema de Validação

Para a implementação computacional, foram utilizados dois problemas, o primeiro um caso real de um provedor de internet de grande escala localizada em Goiás (cujo nome está sob sigilo, Lei LGPD (BRASIL, 2018)). A rede estudada está no nível *backbone* na hierarquia de rede e é um sistema de transporte óptico OTN/WDM, a rede também foi estudada em (DEOLIVEIRA; DESOUZA; VIEIRA, 2020), onde as demandas geradas possuem vinte e sete nós de origem e dois nós de destinos de pontos de comunicações com a WAN (*Wide Area Network*). O segundo, uma rede de menor porte pertencente a biblioteca SNDlib (ORLOWSKI *et al.*, 2010) que contém um sistema de transporte óptico OTN/DWDM.

A Figura 24 ilustra a topologia da rede a ser otimizada, a rede dispõe de 50 links possíveis a serem utilizados e dimensionados para escoar as demandas, a rede OTN/WDM estudada possui três modularidades de transmissão de 40, 100 e 400 Gbit/s. Em todos os testes foi utilizado o software MATLAB® sendo executado em computador com o processador Intel(R) Core(TM) i7-5500U CPU @ 2.4GHz.

Para a rede *backbone*, vinte e sete demandas são estabelecidas para serem escoadas ao mesmo tempo, para dois destinos (N26 e N27). A Tabela 3 contém todas as demandas que irão escoar na rede, sendo que essas demandas foram geradas de forma aleatória no intervalo de [0,5 a 50] Gbit/s. A modelagem possui as seguintes características:

1. Demandas e *links* são bidirecionais;
2. Todos os *links* existentes podem ser utilizados;
3. A demanda prevista não pode ser escoada por mais de um *link*;

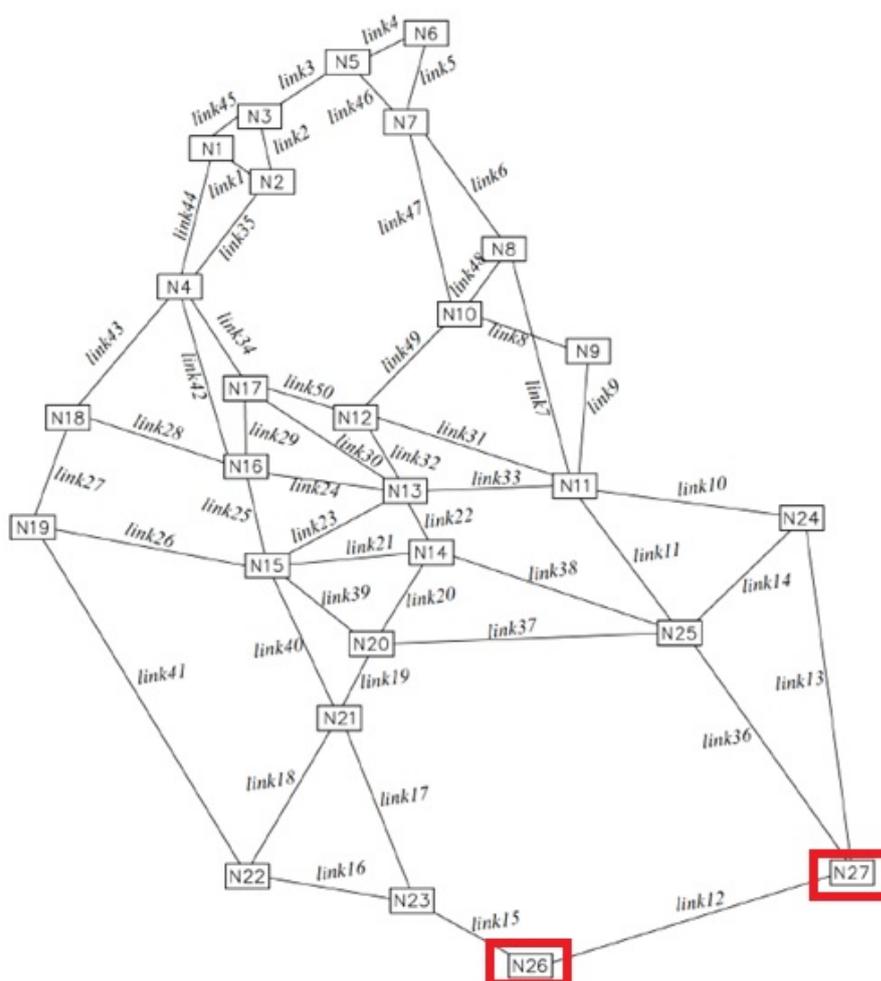


Figura 24 – Rede *backbone* OTN/WDM (DEOLIVEIRA; DESOUZA; VIEIRA, 2020).

4. A capacidade dos *links* é explícita.

Os valores utilizados são relativos. O custo do sistema de modularidade 40 *Gbit/s* (R\$ 89000,00) é utilizado como base, o custo então da rede óptica utilizado descreve um cálculo da média de custo de rede por quilômetro, que é 0,012, sendo representada na Tabela 4.

4.2 Simulação

A escolha dos parâmetros é um dos principais quesitos que afeta o desempenho de um algoritmo. E para se analisar a performance do DCS e DCS-GA na otimização de redes de transportes ópticas foram realizados em 100 simulações, onde, para cada parâmetro foram realizadas 10 testes e a média aritmética está ilustrada Figura 25. Ao decorrer das execuções dos algoritmos, constatou-se que quando se utilizava os valores de 50 e 200 para geração e número de indivíduos, respectivamente, as redes soluções apresentavam menores custos dentro do espaço de soluções. E Yang (YANG; SUASH, 2009) propõe adotar os

Origem	Destino	Demanda (Gbit/s)
N1	N26/N27	13,00
N2	N26/N27	0,50
N3	N26/N27	1,00
N4	N26/N27	5,00
N5	N26/N27	0,50
N6	N26/N27	37,50
N7	N26/N27	1,50
N8	N26/N27	2,50
N9	N26/N27	12,00
N10	N26/N27	2,50
N11	N26/N27	7,50
N12	N26/N27	4,00
N13	N26/N27	20,00
N14	N26/N27	50,00
N15	N26/N27	4,00
N16	N26/N27	10,00
N17	N26/N27	22,50
N18	N26/N27	11,50
N19	N26/N27	12,50
N20	N26/N27	7,50
N21	N26/N27	19,00
N22	N26/N27	3,50
N23	N26/N27	25,00
N24	N26/N27	30,00
N25	N26/N27	15,00
N26	N26/N27	13,00
N27	N26/N27	30,00

Tabela 3 – Demanda prevista para a Rede OTN/WDM.

Modularidade (Gbit/s)	Distância \leq 80km	Distância $>$ 80km
40	1,00	1,32
100	1,90	2,22
400	3,92	4,24

Tabela 4 – Custos dos equipamentos WDM.

seguintes valores de parâmetros para a configuração do algoritmo *Cuckoo Search*, conforme descrito na Tabela 5.

O desempenho do DCS e DCS-GA também é comparado a outras metaheurísticas. Cada algoritmo foi executado 10 vezes. E o critério de parada é o número de gerações (50). A métrica utilizada para mensuração da qualidade das soluções é o menor custo. Para tal análise de desempenho, os Algoritmos *Discrete Cuckoo Search* (DCS) e o híbrido *Discrete Cuckoo Search* com *Genetic Algorithm* (DCS-GA) são comparados com o *Firefly*

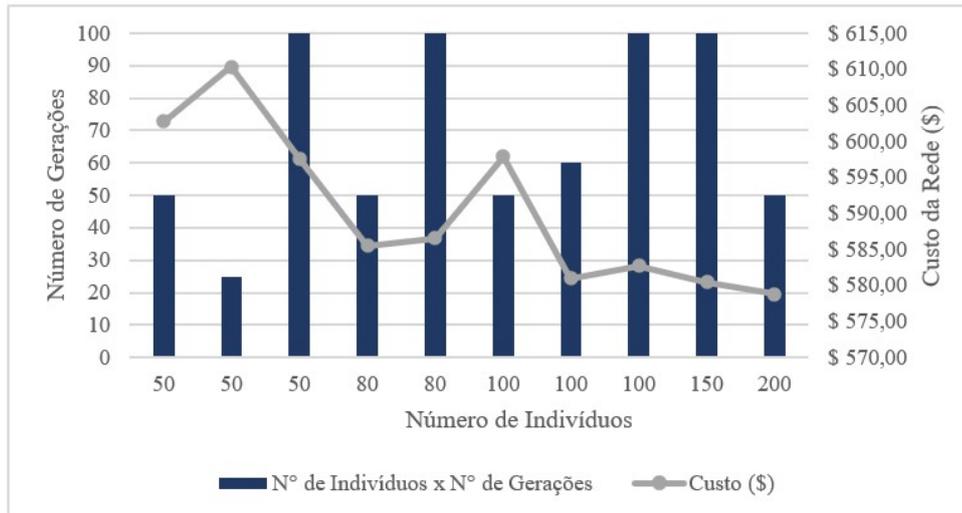


Figura 25 – Gráfico dos resultados de acordo com os parâmetros escolhidos.

Parâmetro	Valor
α	0,01
λ	3/2
Pa	25%

Tabela 5 – Valores de Parâmetros de configuração do *CS*.

Algorithm (FA) e *Hibridy Firefly Algorithm* (HFA) e o clássico Algoritmo Genético (GA). Os resultados estão contidos na Tabela 6, quando é utilizado 5 caminhos mais curtos e quando $k = 20$ na Tabela 7.

Réplica	GA	DCS	FA	HFA	DSC-GA
1	639,74	604,87	577,41	605,48	604,42
2	620,31	604,77	577,41	604,9	586,28
3	629,79	596,68	579,23	588,67	579,27
4	616,12	581,07	577,41	588,45	578,62
5	627,81	579,52	579,07	588,41	578,50
6	637,21	579,49	578,52	587,80	578,50
7	646,61	579,04	578,52	579,84	578,50
8	644,48	578,56	578,12	579,21	578,50
9	634,69	578,37	579,23	578,14	560,33
10	654,44	572,14	577,41	577,44	560,33
Máximo	654,44	604,87	580,46	605,48	604,42
Mínimo	616,12	572,14	577,41	577,44	560,33
Média	635,12	585,85	580,46	581,7496	587,85
Desvio Padrão	11,3	11,93	11,94	8,37	10,22

Tabela 6 – Comparativo de custos entre as Metaheurísticas com $k=5$.

As Figuras 26 e 27 trazem um comparativo de caminhos mais curtos adotado

durante as execuções dos algoritmos. Quando $k=5$ o tempo de processamento é menor, pois cada rede gerada o algoritmo busca somente 5 caminhos mais curtos da origem ao destino. Quando $k = 20$ o tempo de processamento é maior, em compensação, quando o algoritmo procura 20 caminhos mais curtos aumenta a possibilidade de encontrar uma rede factível com custo menor. Sendo k um fator que influencia fortemente o custo da rede .

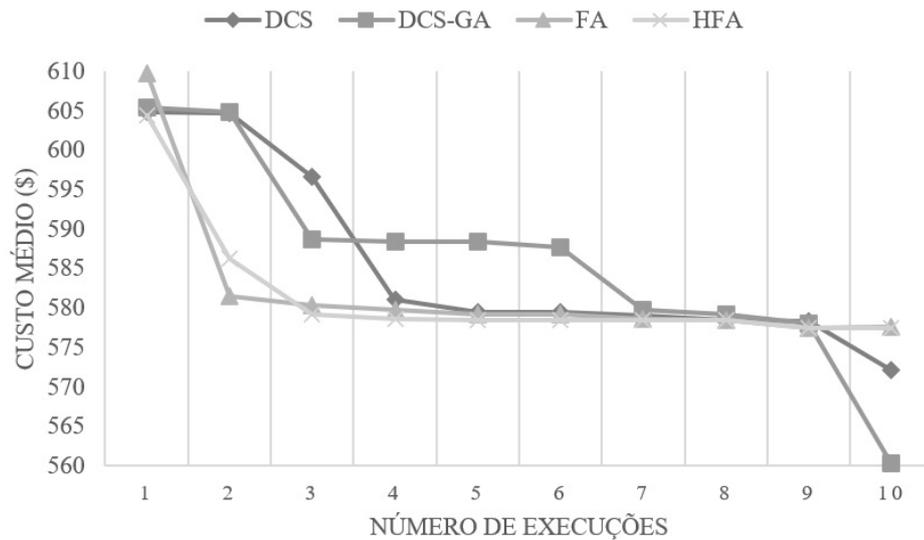


Figura 26 – Comparativo metaheurísticas, $k=5$ caminhos mais curtos.

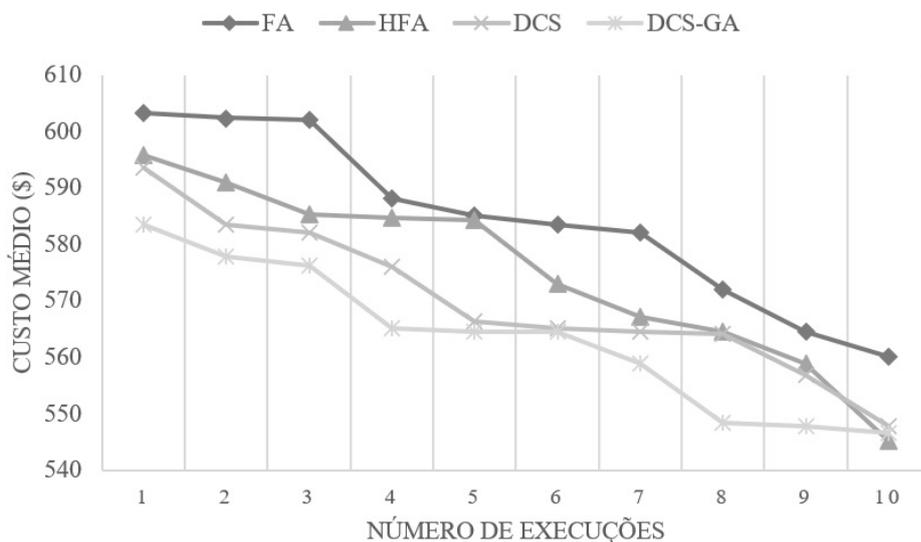


Figura 27 – Comparativo metaheurísticas, $k=20$ caminhos mais curtos.

A Tabela 7 apresenta a comparação dos melhores custos dos GA, FA, HFA, DCS e DCS-GA. *Gap* representa a porcentagem de quanto uma solução está acima do valor ideal (menor custo) encontrado pelo DCS-GA. Assim esse modelo traz a possibilidade de topologias de rede com custos reduzidos, cabendo ao projetista/engenheiro escolher a topologia que mais se adapta a sua realidade.

Método	Menor Custo	Maior Custo	Gap (%)	Custo Médio	Desvio Padrão
FA	567,75	593,51	1,68	574,9795	13,71
HFA	560,65	595,73	2,04	584,36	13,35
DCS	556,20	603,73	3,34	569,99	14,44
DCS-GA	545,20	583,55	0,00	563,36	14,78
GA	548,50	593,55	1,68	573,63	15,79

Tabela 7 – Comparativo de custos entre as Metaheurísticas considerando $k=20$ caminhos mais curtos.

Nas Tabelas 8 e 9, o tempo de processamento de cada metaheurística é mostrado, as tabelas contêm a média de tempo de cada execução. Os algoritmos DCS e DCS-GA mostram tempos de processamento maior, isso se dá ao fato de o algoritmo Busca Cuco apresentar o passo de probabilidade de descoberta, o que trás a probabilidade de desenvolvimento de novas soluções, demandando assim, mais tempo de processamento.

Tempo (s)				
DCS	DCS-GA	FA	HFA	GA
659,75	669,01	408,73	348,91	148,55

Tabela 8 – Tempo de execução, 5 caminhos candidatos.

Tempo (s)				
DCS	DCS-GA	FA	HFA	GA
19131,1	21453,8	15767,1	14418,4	9466

Tabela 9 – Tempo de execução, 20 caminhos candidatos.

A topologia da rede de menor custo é apresentada na Figura 28, onde dos 50 *links* propostos, apenas 26 foram utilizados para o escoamento da demanda total da rede. Foram utilizados 5 *links* de capacidade de 400 Gbit/s, 4 *links* de 100 Gbit/s e 17 *links* de capacidade 40 Gbit/s. Na topologia proposta, nos *links* constam a demanda que está sendo escoada pela capacidade total do *link*. Logo, o algoritmo otimizou redes em que cada *link* possui folga suficiente para um aumento da demanda sem que haja a necessidade de alteração na estrutura da camada física.

Para analisar melhor o desempenho dos métodos e ver a performance do algoritmos DCS e DCS-GA em modelos de redes diferentes, uma nova rede OTN/DWDM de menor porte é proposta. A rede da Figura 29 está contida no repositório SNDlib (ORLOWSKI *et al.*, 2010) e possui 11 nós com 34 possíveis *links* para o escoamento de 11 demandas que possuem 11 nós de origem e dois nós de destino (N2 ou N8) e a capacidade do sistema de 40, 100 ou 400Gbit/s.

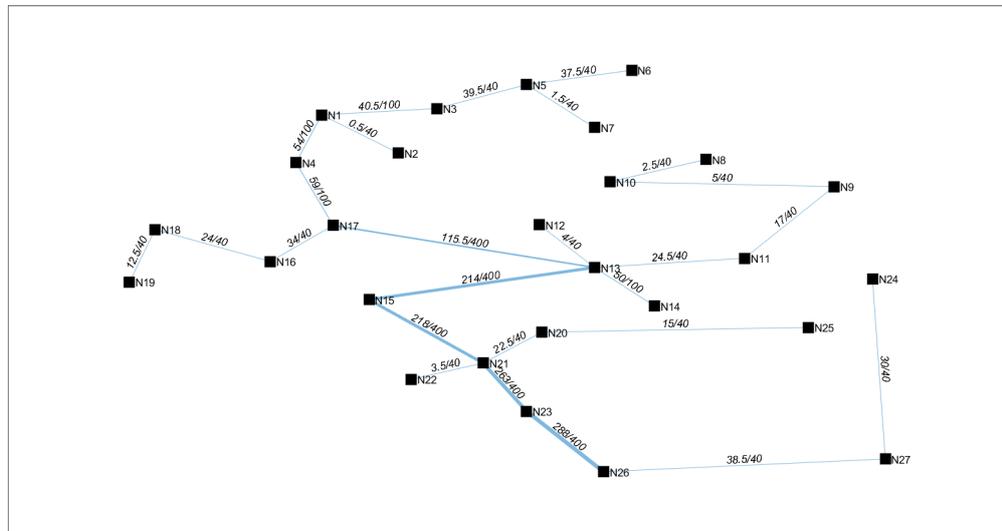


Figura 28 – Topologia de melhor custo \$545,20.

Na Tabela 10 contém os valores de demanda que devem ser escoados das origens até seus nós de destino. Essas demandas foram geradas de forma aleatória na faixa de $[0,5$ a $50] Gbit/s$.

Origem	Destino	Demanda (Gbit/s)
N1	N2/N8	19
N2	N2/N8	42
N3	N2/N8	25
N4	N2/N8	46
N5	N2/N8	21
N6	N2/N8	33
N7	N2/N8	36
N8	N2/N8	08
N9	N2/N8	44
N10	N2/N8	06
N11	N2/N8	47

Tabela 10 – Demanda prevista para a Rede 02 OTN/DWDM.

A Tabela 11 trás a média dos custos e do tempo resultante considerando $k= 10$ e $k=20$ oriundas de dez execuções de cada metaheurística. A versão híbrida do algoritmo DCS trouxe bons resultados com pouca inconstância entre as soluções obtidas, para as duas redes avaliadas. Em ambas as redes propostas os algoritmos DCS e DCS-GA exigiram maior esforço computacional devido a probabilidade de descoberta, esse esforço computacional pode ser compensada pelos melhores custos e pela maior variabilidade de topologias.

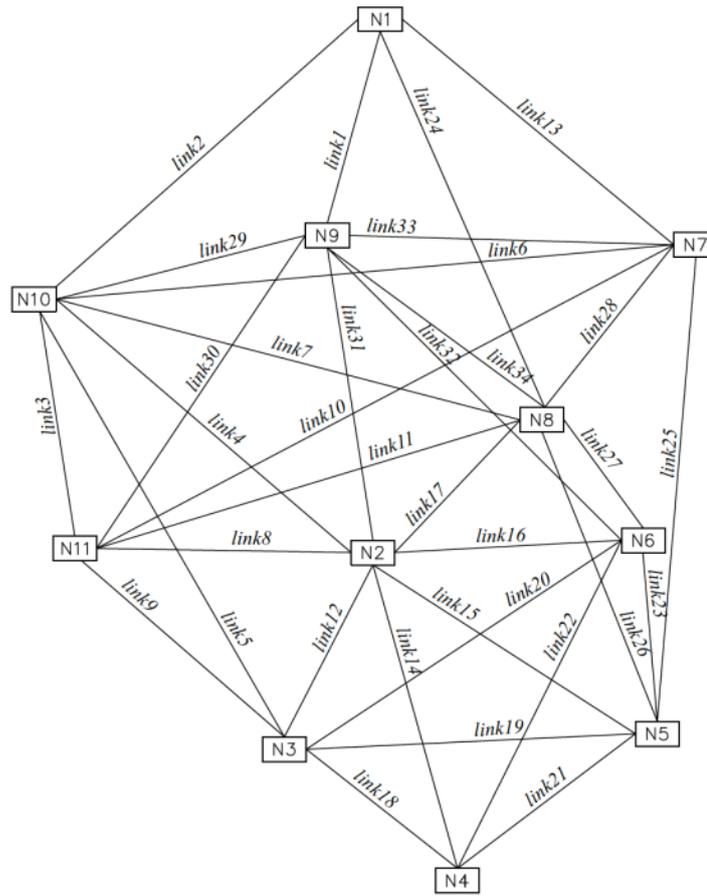


Figura 29 – Rede 02 - OTN/DWDM.

Método	$k=10$			$k=20$		
	Custo	gap (%)	T (s)	Custo	gap (%)	T (s)
DCS	102,94	1,75	421,94	98,44	6,08	450
DCS-GA	101,14	0,00	449,20	92,45	0,00	460
FA	103,03	1,83	212,93	98,44	6,08	221
HFA	102,94	1,75	179,25	97,24	4,93	227
GA	102,94	1,71	267	102,93	11,05	664

Tabela 11 – Comparativo metaheurísticas - Rede 02.

4.3 Comentários Finais

Pode-se resumir então, que os algoritmos DCS e DCS-GA mostraram maior eficiência em relação aos demais, aqui comparados, pois independente da quantidade de caminhos mais curtos escolhidos os algoritmos DCS e DCS-GA trouxeram o menor custo. Por exemplo, para a Rede 02, o algoritmo DCS-GA amostrou uma redução de até 11,05%, se comparado a outros métodos aqui investigados. Para a rede **backbone**, a redução percentual chegou até 3,34%. Os resultados sugerem que o mecanismo proposto gerou rede com custos melhores e topologias diversificadas. Entretanto, quando se compara o desempenho computacional, os algoritmos FA e HFA se mostraram ser mais eficientes,

dado o fato do algoritmo CS em si, possuir a etapa chamada de "probabilidade de descoberta". Essa etapa aumenta a probabilidade de se encontrar topologias mais diversificadas, e conseqüentemente com melhor custo, em contrapartida aumenta o esforço computacional, já que uma parcela das soluções possuirão a probabilidade de serem abandonadas e novas soluções serão construídas, esse esforço computacional é então compensado pela convergência mais rápida à solução com custos menores.

5 CONCLUSÃO

Neste trabalho são propostas algumas estratégias que podem ser aplicadas no dimensionamento e projetos de rede ópticas OTN/WDM de forma otimizada. Estas estratégias lidam com os elementos principais que afetam a relação de custo-desempenho em uma rede óptica: o projeto da topologia física da rede (*Physical Topology Design* (PTD)).

O problema tratado nesse trabalho pertence à classe de algoritmo tipo NP-completo. A sua solução por método exato requer grande esforço computacional, se tornando computacionalmente inviável, até mesmo para redes com o número pequeno de nós. Logo, as propostas apresentadas neste trabalho resolvem os problemas concernentes ao projeto de redes ópticas de forma otimizada.

A rede de transporte é vista como um grafo. A modelagem é então realizada com arco-caminho em contribuição a programação linear inteira mista (MILP), os quais seguem um conjunto de restrições de atendimento de demanda e de capacidade técnica de equipamentos de acordo com as tecnologias avaliadas.

Um método clássico utilizado para definição de um algoritmo de *design* de rede óptica é escolher um conjunto de informações que podem ser estáticas ou dinâmicas sobre o estado de um enlace, então calcular um custo de enlace para esse enlace a partir dessas informações, e em seguida, encontrar o caminho de menor custo que ligue dois nós na rede.

Este trabalho apresentou dois modelos de metaheurísticas, ainda não utilizadas nesse problema de interesse de sistema de apoio para ajudar engenheiros e projetista na tomada de decisão no planejamento de uma rede óptica de telecomunicações. Em resumo, a técnica visa minimizar os custos de implementação, maximizando as folgas, garantindo um aumento efetivo na demanda sem causar danos ao sinal transmitido e sem alterar a estrutura da rede. Os modelos foram otimizados utilizando o *software* MATLAB®, com dados reais de uma rede *backbone* OTN/WDM fornecidos por uma empresa de telecomunicações brasileira do centro oeste e uma rede de menor porte pertencente a SNDlib.

Para o problema do **design** de rede óptica foi proposto dois modelos de otimização, o primeiro é o *Discrete Cuckoo Search* (DCS) que os resultados trouxeram redução nos custos, o segundo é o algoritmo híbrido *Discrete Cuckoo Search* com o *Genetic Algorithm* (GA) intitulado de (DCS-GA). Nesta segunda opção, o tempo de processamento é maior, porém trouxe menor valor de custo das redes, na Rede 02 o algoritmo DCS-GA amostrou uma redução de até 11.05% se comparados a outros métodos aqui investigados. Para a rede *backbone*, a redução percentual chegou até 3.34%.

Os algoritmos foram exaustivamente examinados por meio de simulações. Também foram comparados com outros algoritmos propostos na literatura: FA, HFA e GA. Nos casos analisados o DCS e DCS-GA superaram o FA, HFA e GA, em relação aos custos, quando se tratou de tempo de processamento o FA e HFA mostrou menor tempo de simulação.

Por fim, o objetivo desse trabalho não era trazer um dimensionamento totalmente automatizado, mas sim, trazer estratégias que sirvam como sistemas de apoio a engenheiros e projetistas referente ao planejamento de uma rede óptica em se tratando de uma rede de nível *backbone*, os algoritmos propostos fornecem como resultados um conjunto de topologias (soluções) que realizam uma relação otimizada entre custo e qualidade de sinal (QoS), reforçando o desempenho e colaboração do planejador na tomada de decisão de grande importância.

5.1 Trabalhos Futuros

Para a continuação do trabalho, podem ser realizadas as seguintes atividades:

1. Aplicar os algoritmos desenvolvidos em redes redundantes, é crucial se ter redundância, caso haja falha em um dos enlaces, a rede permanecerá conectada.
2. Avaliar a influência do *Lévy Flight*, nesse problema de interesse, o substituindo por outros métodos probabilísticos.
3. Analisar a influência dos parâmetros do algoritmo genético e do DCS na qualidade das soluções obtidas. Com o propósito de verificar as variações das soluções obtidas conforme os ajustes.

REFERÊNCIAS

- ALKHATEEB, F.; ABED-ALGUNI, B. H. A hybrid cuckoo search and simulated annealing algorithm. *Journal of Intelligent Systems*, v. 28, n. 04, p. 683–698, 2019. Citado na página 48.
- ALSHAMI, A.; DIABAT, A. A genetic algorithm for reserve logistic network design: A case study from the gcc. *Journal os Cleaner Production*, v. 151, p. 652–669, 2017. Citado na página 29.
- ALSHARIF, M. H.; KELECH, A. H.; ALBREEM, M. A.; CHAUDHRY, S. A.; ZIA, M. S.; KIM, S. Six generation (6g) wireless network: Vision, research activities, challenges and potential solutions. *Symmetry*, v. 12, n. 676, 2020. Citado na página 14.
- ANDRÉ, J.; AURAY, S.; BRAC, J.; DE, W. D.; MAISONNIER, G.; M., M.; OULD-SIDI; SIMONNET, A. Design and dimensioning of hydrogen transmission pipeline networks. In: *European Journal of Operational Research*. [S.l.: s.n.], 2013. p. 239–251. Citado na página 29.
- BABUKARTIK, R. G.; DHAVACHELVAN, P. H. Algorithm using the advantage of aco and cuckoo search for job scheduling. *International Journal of Information Technology Convergence and Services*, v. 02, n. 04, p. 25, 2012. Citado na página 48.
- BANDYOPADHYAY, S. *Dissemination of Information in Optical Networks, from Technology to Algorithms*. [S.l.]: Springer, 2007. Citado na página 26.
- BAUMGARTNER, A.; REDDY, V. S.; BAUSHED, T. Combined virtual mobile core network function placement and topology optimization with latency bounds. In: *IEEE Communications Networks*. [S.l.: s.n.], 2015. p. 97–102. Citado na página 29.
- BAZARAA, J. J. J.; SHERALI, H. D. *Linear Programming and Network Flows*. [S.l.]: New York: Willey, 2010. Citado na página 25.
- BAZARAA, M. S.; JARVIS, J. J.; SHERALI, H. D. *Linear Programming and Network Flows*. [S.l.]: New York: Willey, 2010. Citado na página 26.
- BELLO-SALAU, H.; ONUMANYI, A. J.; ABU-MAHFOUZ, A. M.; ADEJO, A. O.; MUAZU, M. B. New discrete cuckoo search optimization algorithms for effective route discovery in iot-based vehicular ad-hoc networks. *IEEE Access*, v. 8, p. 145469–145488, 2020. Citado na página 17.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM COMPUTING SURVEYS*, p. 268–308, 2003. Citado na página 16.
- BRASIL. Lei, 13.709, 14 de agosto de 2018. *Lei Geral de Proteção de Dados*, 2018. Citado na página 52.

- CAMPOS, E.; CUNHA, V. H.; DANTAS, J. P.; GUIMARÃES, L. C.; LIMA, C. A.; DEOLIVEIRA, B. Q. Network design genetic algorithm (ndga) aplicado em redes de telecomunicações. In: *4ª Conferência Ibero-Americana Computação Aplicada - Lisboa*. Lisboa-Portugal: [s.n.], 2016. Citado na página 29.
- CHEKURI, C. Routing and network design with robustness to changing or uncertain traffic demands. *ACM SIGACT News*, v. 38, n. 3, p. 106–129, 2007. Citado na página 14.
- CRUZ, P. P.; GUTIÉRREZ, A. M.; MENDONZA, R. A. R.; FLORES, E. M.; ESPINOZA, A. A. O.; SILVA, D. C. B. A practical approach to metaheuristic using labview and matlab. *A CHAPMAN HALL BOOK*, 2020. Citado na página 16.
- CÉSAR, G. L. Fundamentos do padrão otn (optical transport networks). *Tese de Doutorado*, USP, 2014. Citado na página 22.
- DAOUD, E. A. A hybrid algorithm using a genetic algorithm and cuckoo search algorithm to solve the traveling salesman problem and its application to multiple sequence alignment. *International Journal of Advanced Science and Technology*, v. 61, p. 29–38, 2013. Citado na página 48.
- DEOLIVEIRA, B.; DESOUSA, M.; VIEIRA, F. A hybrid firefly-genetic algorithm for planning of optical transport networks. *Journal of Communication and Information Systems*, v. 35, n. 1, 2020. Citado 4 vezes nas páginas 8, 16, 52 e 53.
- DESOUSA, M.; DEOLIVEIRA, B.; DANTAS, M.; SANTANA, A.; BRAGANÇA, F. Modeling a support system for choosing telecommunications services. *Conferência Ibero-Americana Computação Aplicada*, 2014. Citado na página 15.
- DIAZ, B. B.; ROA-PINTO, P.; LUCKEN, C. v. Robust network design under uncertain traffic an approach based on genetic algorithm. *XXXIX Latin American Computing Conference (CLEI)*, 2013. Citado na página 15.
- DIN, D. Genetic algorithm for virtual topology design on mlr wdm networks. *Optical Switching and Networking*, v. 18, p. 20–34, 2015. Citado na página 16.
- DIN, D. Heuristic and genetic algorithms for solving the virtual topology design problem on elastic optical networks. *Optical Switching and Networking*, v. 33, 2017. Citado na página 16.
- EIRA, A.; SANTOS, A.; PEDRO, J.; PIRES, J. Multi-objective design of survivable flexible-grid dwdm networks. *J. OPT. COMMUN. NETW*, v. 06, 2014. Citado na página 16.
- FERNANDEZ, S.; JUAN, A. A. J.; TERRÉN, D. Metaheuristic in telecommunication systems: Network design, routing, and allocation problems. *IEEE SYSTEMS JOURNAL*, v. 12, n. 14, p. 3948–3957, 2018. Citado 2 vezes nas páginas 14 e 16.
- FILHO, C.; BASTOS, J. A. Sistemas de comunicações Ópticas. *Escola Politécnica de Pernambuco-UFPE*, 2010. Citado na página 20.
- GANDOMI, A.; YANG, X.; ALAVI, A. Cuckoo search algorithm: a metaheuristic approach to solve structural optimization problems. *Engineering with Computers* 29, p. 17–35, 2013. Citado na página 17.

- GILCHRIST, A. *OTN (optical transport networks): G.709 Simplified RG Consulting*. [S.l.]: Editora, 2015. Citado 3 vezes nas páginas 8, 22 e 24.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. [S.l.]: Addison-Wesley Publishing Company, 1989. Citado na página 32.
- HARUNA, M.; JINNO, M.; NISHIO, Y. Application of firefly algorithm to optimization of translucent elastic optical network. *Proc. of Nonlinear Theory and its Applications Conference*, 2015. Citado na página 16.
- HICKS, C. A genetic algorithm tool for optimising cellular or functional layouts in the capital goods industry. In: *International Journal of Production Economics*. [S.l.: s.n.], 2006. p. 598–614. Citado na página 32.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. [S.l.]: MIT Press, 1975. Citado na página 28.
- IANNONE, E. *Telecommunication networks*. CRC Press, 2016. Citado na página 20.
- JORGE, J. M. d. A. G. *Redes Ópticas de transporte. Dissertação de mestrado*, Universidade de Aveiro, Aveiro, 2012. Citado 2 vezes nas páginas 8 e 23.
- KANAGARAJ, G.; PONNAMBALAM, S.; JAWAHAR, N. A hybrid cuckoo search and genetic algorithm for reliability redundancy allocation problems. *Computers & Industrial Engineering*, v. 66, p. 1115–1124, 2013. Citado na página 36.
- KANAGARAJ, G.; PONNAMBALAM, S.; JAWAHAR, N. A hybrid cuckoo search and genetic algorithm for reliability redundancy allocation problems. *Computers and Industrial Engineering*, v. 66, p. 1115–1124, 2013. Citado na página 48.
- KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. In: *Reliability Engineering System Safety*. [S.l.: s.n.], 2006. p. 992–1007. Citado 2 vezes nas páginas 31 e 32.
- KUMAR, A.; GUPTA, M. A review on activities of fifth generation mobile communication systems. *Alexandria Engineering Journal*, 2017. Citado na página 14.
- LI, S.; XU, L. D.; ZHAO, S. 5g internet of things: A survey. *Journal of Industrial Information Integration*, 2018. Citado na página 14.
- LIMA, R.; DEOLIVEIRA, B.; CARNEIRO, M. Otimização da rede de transportes Ópticas: Revisão e complexidade. *XLI Encontro Nacional de Engenharia de Produção*, 2021. Citado na página 16.
- LINDEN, R. *Algoritmos Genéticos*. [S.l.]: Rio de Janeiro: Ciência Moderna Ltda, 2012. Citado na página 29.
- LIU, X.; DENG, N. Emerging optical communication technologies for 5g. *Optical Fiber Telecommunications VII*, p. 751–783, 2020. Citado na página 14.
- LONG, W.; CAI, S.; JIAO, J.; XU, M.; WU, T. A new hybrid algorithm based on grey wolf optimizer and cuckoo search for parameter extraction of solar photovoltaic models. *Energy Conversion and Management*, 2020. Citado na página 48.

- MANSOURI, M. H. A. H. M. R. Optimization of the water distribution networks with differential evolution (de) and mixed integer linear programming (milp). *Journal of Water Resource and Protection*, 2015. Citado na página 29.
- MANTEGNA, R. N.; STANLEY, H. E. Stochastic process with ultraslow convergence to a gaussian: The truncated lévy flight. *Physical review letters*, v. 73, n. 22, p. 2946–2949, 1994. Citado na página 34.
- MARTINS, E. *An algorithm for ranking optimal paths*. [S.l.]: www.mat.uc.pt/marta/Publicacoes/rank_optimal.ps.gz, 2017. Citado na página 27.
- MATA, J.; MIGUEL, I. de; DURAN, R. J.; MERAYO, N.; SINGH, S. K.; JUKAN, A.; CHAMANIA, M. Artificial intelligence (ai) methods in optical networks: A comprehensive survey. *Optical switching and networking*, v. 28, p. 47–57, 2018. Citado na página 16.
- MAZDA, F. *Telecommunications engineer's reference book*. [S.l.]: Butterworth-Heinemann, 2014. Citado na página 22.
- MONTEIRO, V. C. e B. O. Rede de transporte otn- optical transport network. *II SRST - Seminário de Redes e Sistemas de Telecomunicações*, 2015. Citado na página 21.
- MUNTAZ, S.; MORGADO, A.; HUQ, K. M. S.; RODRIGUES, J. A survey of 5g technologies: Regulatory, standardization and industrial perspective. *Digital Communications and Networks*, 2017. Citado na página 14.
- MUSUMECI, F.; ROTTONDI, C.; NAG, A.; MACALUSO, I.; ZIBAR, D.; RUFFINI, M.; TORNATORE, M. An overview on application of machine learning techniques in optical networks. *IEEE Communications Surveys Tutorials*, v. 21, n. 2, p. 1383–1408, 2019. Citado na página 16.
- OHARA, T.; TESHIMA, M.; AISAWA, S.; JINNO, M. Otn technology for multi-flow optical transponder in elastic 400g/1t transmission era. *OFC/NFOEC*, p. 1–3, 2012. Citado na página 14.
- ORLOWSKI, S.; WESSALY, R.; PIÓRO, M.; TOMASZEWSKI, A. Sndlib 1.0 - survivable network design library. *Networks*, p. 276–286, 2010. Citado 2 vezes nas páginas 52 e 57.
- OUAARAB, A.; AHIOD, B.; YANG, X. Discrete cuckoo search algorithm for the travelling salesman problem. *Neural Comput and Applic*, v. 24, p. 16591669, 2014. Citado na página 17.
- OUAARAB, B. A. e X. . S. A. M. Y. A. Discrete cuckoo search algorithm for jobshop scheduling problem. *IEEE International Symposium on Intelligent Control (ISIC)*, p. 1872–1876, 2014. Citado na página 34.
- PAPAGIANNI, C. e. a. Communication network design using particle swarm optimization. *IEEE International Multiconference on Computer Science and Information Technology*, p. 915–920, 2008. Citado na página 16.
- PAVLYUKEVICH, I. Levy flights, non-local search and simulated annealing. *Journal of Computational Physics*, v. 226, p. 1830–1844, 2007. Citado na página 33.

PERALTA, R. C.; FORGHANI, A.; FAYAD, H. Multiobjective genetic algorithm conjunctive use optimization for production, cost, and energy with dynamic return flow. *Journal of Hydrology*, p. 776–785, 2014. Citado na página 29.

PERERIRA, H. A.; CHAVES, D. A. R.; BASTOS-FILHO, C. A.; MARTINS-FILHO, J. F. Osnr model to consider physical layer impairments in transparent optical networks. *Photonic Networks Communications*, v. 18, n. 02, p. 137–149, 2009. Citado na página 24.

PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; MIRANDA, R. C. *Algoritmos Genéticos: Fundamentos e Aplicações*. [S.l.]: Meta-Heurísticas em Pesquisa Operacional, Omnipax, 2013. Citado na página 29.

PIÓRO, M.; MEDHI, D. *Routing flow, and capacity design in communication and computer networks*. [S.l.]: Elsevier, 2004. Citado na página 27.

PRATA, B. de A. A hybrid genetic algorithm for the vehicle and crew scheduling in mass transit systems. *IEEE Latin America Transactions*, v. 13, n. 9, p. 3020–3025, 2015. Citado na página 30.

RAI, S.; MUKHERJEE, B.; SU, C.; HAMADA, T. Provisioning in ultra-long-haul optical networks. *Conference on Optical Fiber Communication and the National Fiber Optic Engineers Conference (OFC/NFOEC)*, 2007. Citado na página 24.

RAMAMURTHY, B.; FENG, H.; DATTA, D.; HERITAGE, J. M. B. Transparent vs. opaque vs. translucent wavelength-routed optical networks. *Optical Fiber Communication Conference and the International Conference on Integrated Optics and Optimal Fiber Communication (OFC/IOOC)*, 1999. Citado na página 24.

RAMAMURTHY, S.; SAHASRADUDDHE, L.; MUKHERJEE, B. Survivable wdm mesh networks. *Journal of Lightwave Technology*, p. 870–883, 2003. Citado na página 20.

ROMERO, R.; MANTOVANI, J. Introdução a metaheurísticas. *3^o Congresso Temático de Dinâmica e Controle da SBMAC*, p. 1872–1876, 2004. Citado 3 vezes nas páginas 43, 45 e 50.

RUBIO, A.; VEJA, M. A.; GONZÁLEZ, D. L. An improved multiobjective approach inspired by the flashing behaviour of fireflies for traffic grooming in optical wdm networks. *Applied Soft Computing*, p. 617–636, 2014. Citado na página 16.

SAENGUDOMLERT, P. Power-aware logical topology selection for ip-over-wdm backbone networks based on per-lightpath power consumption model. *2014 11th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, p. 1–4, 2014. Citado na página 14.

SAENGUDOMLERT, P. Power-aware logical topology selection for ip-overwdm backbone networks based on per-lightpath power consumption model. *In Eletrical Engineering/Electronics, Computer, Telecommunications and Informayion Technology (ECTI-CON)*, 2014. Citado na página 26.

SHANNON, C. E. Communication in the presence of noise. *in Proceedings of the IRE*, p. 10–21, 1949. Citado na página 20.

- SHEN, G.; TUCKER, R. S. Translucent optical networks: the way forward. *IEEE Communications Magazine*, v. 45, n. 02, p. 48–54, 2007. Citado na página 24.
- SIMMONS, J. M. *Optical Network Design and Planning*. [S.l.]: Springer, 2008. Citado 2 vezes nas páginas 8 e 21.
- STRAND, J.; CHU, A.; TRACK, R. Issues for routing in the optical layer. *IEEE Communications Magazine*, v. 39, n. 02, p. 81–87, 2001. Citado na página 24.
- SYGLETOS, S.; TOMKOS, I.; LEUTHOLD, J. Technological challenges on the road toward transparent networking. *Journal of Optical Networking*, v. 07, n. 04, p. 81–87, 2004. Citado na página 24.
- TESSINARI, R. S. Integração do plano de transporte com planos de controle e de gerência em redes otn: Uma abordagem via simulação. *Universidade Federal do Espírito Santo*, Vitória, Brasil, 2011. Citado na página 22.
- TEXEIRA, A. B. A.; BATISTA, C. T.; CARDOSO, A. J. F.; ARAÚJO, J. D. S. A generic algorithm approach for static routing and wavelength assignment in all-optical wdm networks. In *Portuguese Conference on Artificial Intelligence*, 2017. Citado na página 28.
- TRIAY, J.; CERVELLO, C. An ant-based algorithm for distributed routing and wavelength assignment in dynamic optical networks. *IEEE Journal on Selected Areas in Communications*, v. 28, p. 542–552, 2010. Citado na página 16.
- WANG, F.; LUO, L.; HE, X. S.; WANG, Y. Hybrid optimization algorithm of pso and cuckoo search. *2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce (AIMSEC)*, 2011. Citado na página 48.
- YANASSE, H.; ARENALES, M.; MORABITO, R.; ARMENTANO, V. *Pesquisa Operacional*. [S.l.]: NEA. Citado na página 14.
- YANG, S.; JIANG, Y.; NGUYEN, T. T. Metaheuristic for dynamic combinatorial optimization problems. *IMA Journal of Management Mathematics Advance Access*, p. 1–30, 2012. Citado 2 vezes nas páginas 15 e 16.
- YANG v.; CHIEN, S. F.; TING, T. O. Bio-inspired computation in telecommunications. *Morgan Kaufmann*, 2015. Citado na página 16.
- YANG, X. S. *Nature-Inspired Metaheuristic Algorithms*. [S.l.]: Luniver Press, 2010. Citado na página 16.
- YANG, X.-S.; SUASH, D. Cuckoo search via lévy flights. In: *Proc. of World Congress on Nature Biologically Inspired Computing (NaBIC 2009)*. [S.l.: s.n.], 2009. p. 210–214. Citado 3 vezes nas páginas 16, 33 e 53.
- YEN, J. Y. Finding the k shortest loopless path in a network. *Management Science*, p. 712–716, 1971. Citado na página 28.