LIII Simpósio Brasileiro de Pesquisa Operacional
João Pessoa - PB, 3 a 5 de novembro de 2021

NSGA-II com parâmetros adaptativos aplicado ao design de redes de telecomunicação

Valdomiro Roberto Damaceno Neto
Pontifícia Universidade Católica de Goiás - PUC GO
Av. Universitária 1440 - Setor Leste Universitário, Goiânia - GO, 74175-120
valdomiroapc@gmail.com

Maria Jose Pereira Dantas
Pontifícia Universidade Católica de Goiás - PUC GO
Av. Universitária 1440 - Setor Leste Universitário, Goiânia - GO, 74175-120
mjpdantas@gmail.com

RESUMO

Neste trabalho, é realizada a aplicação de um algoritmo genético adaptativo baseado na ordenação não dominada (ANSGA-II) ao *design* de redes de telecomunicações abordado de forma bi-objetivo. Os resultados do ANSGA-II foram comparados com trabalhos que resolvem o problema de *design* de redes de forma mono-objetivo. Obteve-se bons resultados, tendo em vista, que foi gerado um amplo conjunto de soluções não dominadas muito próximas da frente ótima de Pareto para a instância testada, assim como boas soluções quando comparadas com outros trabalhos.

PALAVRAS CHAVE. ***Design*** **de redes de telecomunicação, NSGA-II, Metaheurísticas, Otimização multiobjetivo, Mecanismos adaptativos.**

Tópicos (TEL $\&$ **SI** $-$ **PO em Telecomunicações e Sistemas de Informações, MH** $-$ **Metaheurísticas)**

ABSTRACT

In this paper, the application of an adaptive genetic algorithm based on non-dominated sorting (ANSGA-II) to telecommunication network design approached in a bi-objective manner is performed. The results of ANSGA-II were compared with works that solve the network design problem in a mono-objective manner. Good results were obtained, since a large set of non-dominated solutions were generated, very close to the Pareto optimal front-end for the instance tested, as well as good solutions when compared to other works.

KEYWORDS. Telecommunication Network Design, NSGA-II, Metaheuristics,Multi-objective optimization, Adaptive mechanism.

Paper topics (TEL $\&$ **SI** $-$ **OR in Telecommunication and Information Systems, MH** $-$ **Metaheuristics)**

1. Introdução

Segundo [Fernandez et al., 2018], o *design* de redes representa um dos problemas de otimização combinatória (COPs) mais difíceis do ramo de telecomunicações. Esse problema é relacionado com o planejamento tático e estratégico dos recursos da rede. Esse problema é frequentemente encontrado em várias aplicações do mundo real.

Na literatura, há uma clara tendência a encarar o problema de *design* de redes de telecomunicações como um problema de otimização multiobjetivo [Fernandez et al., 2018]. Com base nesta informação, neste trabalho, foi proposto um algoritmo genético adaptativo baseado na ordenação não dominada (ANSGA-II - *Adaptive Non-dominated Sorting Genetic Algorithm*) encontrado no trabalho de [Li et al., 2015], a fim de obter um conjunto amplo de soluções de qualidade para o problema do *design* de rede, otimizando o custo e soma do número de *links* (*Hops*) que cada demanda deverá atravessar para chegar ao destino. O custo é um fator que beneficia diretamente a empresa que deseja desenvolver uma rede de telecomunicações. No trabalho de [Kallo et al., 2004], afirma-se que minimizando o número de *Hops*, aumenta-se a mobilidade na rede, consequentemente, aumentando a taxa de transferência, proporcionando menor *delay* na entrega dos pacotes e reduzindo a sobrecarga na comunicação. Com isso, pode-se afirmar que ambos os objetivos são relevantes.

No trabalho de [Li et al., 2015], realizou-se um estudo comparativo entre o ANSGA-II e o Algoritmo evolucionário adaptativo e multiobjetivo baseado em decomposição (AMOEA/D - *Adaptive Multiobjective Evolutionary Algorithm Based on Decomposition*). Chegando a conclusão de que o ANSGA-II tem performance superior ao AMOEA/D no problema *multi-stage weapon target assignment*, e que os mecanismos adaptativos adotados, fazem o NSGA-II ter um melhor desempenho. [Verma et al., 2021] destaca em suas direções futuras, o uso de parâmetros dinâmicos para melhorar o NSGA-II, também destaca a popularidade do NSGA-II na resolução de problemas de otimização combinatória. Não foram encontrados trabalhos que aplicassem o ANSGA-II ao problema de *design* de redes, no contexto de telecomunicações. Os trabalhos acima citados juntamente com o trabalho de [Fernandez et al., 2018], motivaram os autores deste trabalho a aplicar o ANSGA-II ao problema de *design* de redes de telecomunicações modelado de forma bi-objetivo.

Descrevendo brevemente o problema com apoio no trabalho de [Wang et al., 2018], uma rede de telecomunicações pode ser representada como um grafo composto de nós (*switches*, roteadores, *hubs* etc.), *links* (cabos de fibra óptica, cabos par-trançado etc.) e demandas, representadas por um nó de origem, um nó de destino e o volume de dados a ser enviado da origem até o destino. Esse problema pode ser modelado como o *Capacited Network Design Problem* (CNDP), que consiste em selecionar os *links* e alocar capacidades nesses *links*, de forma que seja possível enviar através da rede, os dados da demanda, da origem, até o destino, levando em consideração critérios como desempenho, custo e confiabilidade.

Este trabalho foi dividido em 6 seções. Na seção 2, apresentamos as definições básicas para facilitar o entendimento do artigo. Na seção 3, é apresentada a definição matemática para o problema, no formato de programação linear inteira. Na seção 4 explica-se o algoritmo proposto, passo a passo. Na seção 5, mostra-se os resultados obtidos e as comparações. Finalmente, na seção 6, são apresentadas as conclusões obtidas a partir deste trabalho e abordagens futuras.

2. Definições básicas

Um problema de otimização multiobjetivo pode ser definido matematicamente conforme as equações (1-4) [Ojha et al., 2019]:

$$\min F(x) = [f_1(x), ..., f_m(x)]; m \geq 2 \tag{1}$$

sujeito a:

$$g_j(x) \leq 0, j = 1, 2, ..., J \tag{2}$$

$$h_k(x) = 0, k = 1, 2, ..., K \tag{3}$$

$$x_{li} \leq x_i \leq x_{ui}, i = 1, 2, ..., n \tag{4}$$

Uma solução $x = (x_1, x_2, ..., x_n)^T, x \in X$ é um vetor com n variáveis de decisão. Cada variável de decisão x_i está sujeito a um limite inferior x_{li} e um limite superior x_{ui}. O espaço de decisão válido X é definido como o conjunto $\{x|g_j(x), j = 1, 2, ..., J; h_k(x) = 0, k = 1, 2, ..., K\}$. As funções objetivo $f_m(x)$ geralmente representadas por funções de custo, lucro ou valor, são as funções que devem ser minimizadas ou maximizadas, tendo em vista que, as funções a serem maximizadas, podem ser convertidas em funções a serem minimizadas, multiplicando por -1 com base no princípio da dualidade. O espaço objetivo $\mathbb{R}^n$ pode ser definido como o conjunto $\{F(x)|x \in X\}$.

Definição 1: Dominância de Pareto: Para dois vetores de decisão x e y, é dito que x domina y (denotado por $x \prec y$) se $\forall m \in 1, 2, ..., M$, $f_m(x) \leq f_m(y)$ e $\exists m \in 1, 2, ..., M$, $f_m(x) < f_m(y)$.

Definição 2: Eficiência de Pareto: uma solução $x \in \mathbb{R}^n$ é dita eficiente, se e apenas se $\nexists y \in \mathbb{R}^n$, tal que $y \prec x$.

Definição 3: Conjunto eficiente de Pareto (PS) é o conjunto de todas as soluções eficientes. A imagem de PS no espaço objetivo é chamada de frente de Pareto (PF). Esta frente representa os melhores *trade-off* para o problema.

3. Formulação matemática

O problema de *design* de redes pode ser representado por um grafo $G = (V, E, D)$, sendo V, o conjunto de nós, E o conjunto de *links* e D o conjunto de caminhos válidos. Cada demanda $d \in D$, contém o valor da demanda $h_d \in \mathbb{R}^+$ a ser enviado de um nó de origem, até o nó de destino. Além disso, cada demanda contém um conjunto de caminhos válidos P_d, cada caminho $p \in P_d$ tem a mesma origem e destino. O conjunto total de caminhos válidos na rede é representado por $P = \bigcup_{d \in D} P_d$. A variável binária x_p^d, indica se a demanda será escoada pelo caminho p. Neste trabalho, considera-se que apenas um caminho pode ser tomado para escoamento da demanda. Para cada *link* $e \in E$, é dado um conjunto de módulos de capacidade T_e. Cada módulo $t \in T_e$ fornece uma capacidade c_e^t ao *link* e. Além disso, cada *link* e contém uma capacidade inicial C_e(que pode ser igual a zero). A variável y_e^t indica se o módulo t está ou não instalado, é uma variável binária, sendo que apenas um módulo t pode ser instalado por *link* e. Temos também o conjunto de caminhos válidos Q_e que passam pelo *link* e, $Q_e := \{p \in P|e \in p\}$. Considerando que neste trabalho estão sendo tratados dois objetivos a serem minimizados, segue a equção (1), descrevendo a função que representa o custo da rede:

$$f_1 = \sum_{e \in E} (K_e + \sum_{t \in T} k_e^t y_e^t) \tag{5}$$

Sendo, k_e^t o custo de instalação do módulo t no *link* e. Seja $\delta : p \rightarrow \mathbb{Z}^+$, a função que calcula a quantidade de *Hops* em um caminho válido. Segue a equação (2), descrevendo a função que calcula a soma de *Hops* da rede:

$$f_2 = \sum_{d \in D} \sum_{p \in P_d} \delta(p) \tag{6}$$

Segue o modelo programação linear inteira para o problema de *design* de redes de telecomunicações:

$$\min f = (f_1, f_2) \tag{7}$$

Sujeito a:

$$\sum_{p \in P_d} x_p^d = 1, \forall d \in D \tag{8}$$

$$\sum_{t \in T_e} y_e^t \leq 1, \forall e \in E \tag{9}$$

$$\sum_{p \in Q_e} x_p^d h_d \leq C_e + \sum_{t \in T_e} y_e^t c_e^t, \forall e \in E, \forall d \in D \tag{10}$$

$$x_p^d \in \{0,1\}, \forall d \in D, \forall p \in P \tag{11}$$

$$y_e^t \in \{0,1\}, \forall t \in T_e, \forall e \in E \tag{12}$$

A restrição (8), garante que para cada demanda, exatamente um caminho será usado. A restrição (9), garante que um ou nenhum módulo será instalado no *link* e. A restrição (10), garante que o fluxo que passa pelo *link* e não será maior que a capacidade instalada neste *link*. (11) e (12) definem as variáveis de decisão como binárias. (7) Representa a função objetivo referente ao problema. O modelo descrito é uma adaptação da formulação disponível no trabalho de Orlowski [Orlowski et al., 2007]

4. ANSGA-II

Com apoio em [Li et al., 2015], nesta seção, será apresentado o algoritmo genético adaptativo baseado em ordenação não dominada (ANSGA-II), sendo uma adaptação do algoritmo genético baseado em ordenação não dominada (NSGA-II). O NSGA-II é um algoritmo que otimiza vários objetivos simultaneamente com base em dois fatores, a dominância de Pareto e a distância de aglomeração. Neste trabalho, foi realizado um cálculo prévio do conjunto de caminhos que serão usados pelo ANSGA-II. A Figura 1 contém o fluxograma do algoritmo ANSGA-II proposto. Primeiro, são gerados para cada demanda um conjunto de 10 caminhos válidos para cada demanda, de acordo com a formulação matemática. Em seguida, é gerada a população inicial com 75 indivíduos, número escolhido de forma a manter o desempenho do algoritmo e maximizar o número de indivíduos. Então, até que o tempo de execução tenha acabado, são executados os operadores de mutação e cruzamento com mecanismos adaptativos, e a ordenação não dominada e distância de aglomeração, seguidos do operador de seleção. Cada elemento do ANSGA-II será explicado a seguir.

4.1. Cálculo do Conjunto de caminhos

Para a execução do algoritmo, foi gerado um conjunto de caminhos para cada demanda usando o algoritmo K-caminhos. Para maior aprofundamento no algoritmo, o leitor pode verificar o trabalho de [Xu et al., 2012]. O algoritmo K-caminhos padrão é implementado usando o algoritmo de dijkstra que é amplamente conhecido na literatura. No entanto, neste trabalho usa-se o algoritmo *breadth first search* (BFS) no algoritmo K-caminhos, pois convém na otimização do número de *Hops*. Para cada demanda são gerados 10 caminhos distintos, gerando assim os $|D|$ conjuntos de caminhos P_d. Essa estratégia também é utilizada no trabalho de Oliveira [Oliveira, 2020].

4.2. Representação do cromossomo

Conforme a formulação matemática, $p \in P_d$ é um caminho (conjunto de arestas no grafo) que serve para escoar uma demanda. Neste documento, o cromossomo tem o comprimento $|D|$, e cada gene representa o caminho p pelo qual a demanda $d \in D$ pode ser escoada. A Figura 2 representa o cromossomo adotado neste trabalho:

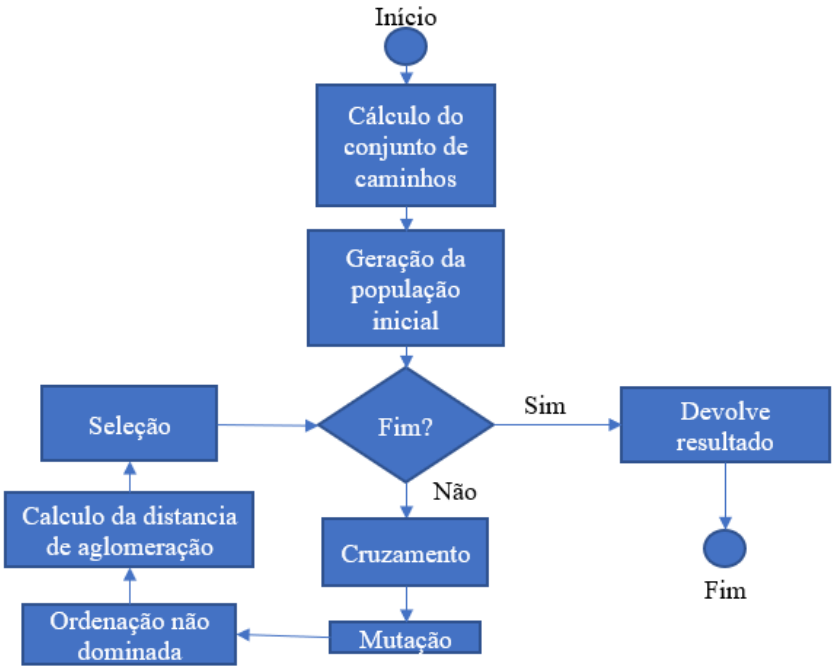


Figura 1: Fluxograma de execução ANSGA-II



Figura 2: Representação do cromossomo ANSGA-II

4.3. Geração da população inicial

A população inicial é gerada aleatóriamente, sorteando para cada gene um caminho $p \in P_d$ do conjunto que é valido para a demanda $d \in D$ correspondente ao gene. Após isso, é feito o cálculo do custo e da soma de *Hops*. Em seguida, é aplicado uma busca local que será explicada mais à frente no documento. Soluções inválidas são penalizadas com um enorme valor de custo, afim de que ela não se sobressaía no algoritmo.

4.4. Mecanismo Adaptativo

Foi implementado neste trabalho, os mecanismos adaptativos conforme o trabalho de [Li et al., 2015]. Este mecanismo disponibiliza uma alta probabilidade de cruzamento para boas soluções com a ideia de que os bons geram melhores. O objetivo do mecanismo adaptativo é manter boas estruturas de boas soluções para a próxima geração. Seja r_i o *rank* do indivíduo i e pc_i é a probabilidade de cruzamento do indivíduo i, e pm_i é a probabilidade de mutação do indivíduo i. A equação (13) representa o mecanismos adaptativos aplicados aos operadores de cruzamento e mutação.

$$pc_i = \begin{cases} k_1 \frac{\overline{r} - r_{min}}{r_i - r_{min}} & \text{, se } r_i > \overline{r} \\ k_3 & \text{, se } r_i \leq \overline{r} \end{cases}, \quad pm_i = \begin{cases} k_2 \frac{r_i - r_{min}}{\overline{r} - r_{min}} & \text{, se } r_i \leq \overline{r} \text{ e } \overline{r} > r_{min} \\ k_4 & \text{, se } r > \overline{r} \end{cases} \tag{13}$$

Onde $\overline{r}$ representa a média dos *ranks* da população, r_{min} representa o menor *rank* da população. No operador de cruzamento, r_i representa o menor *rank* entre os dois indivíduos envolvidos no

cruzamento. k_1, k_2, k_3 e k_4 são constantes que definem o valor máximo dessas operações. $k_1 = 1$, $k_2 = 0,5$, $k_3 = k_1$, $k_4 = k_2$

4.5. Operador de cruzamento

O operador de cruzamento utilizado neste trabalho, seleciona dois indivíduos usando um torneio com 3 *rounds*. Inicialmente, são tomados dois elementos aleatórios da população. O melhor entre eles avança para o próximo *round*, onde é sorteado outro elemento e é realizada a comparação com o vencedor do *round* anterior. Este procedimento é feito duas vezes, até obter dois indivíduos. Após isso, se uma condição com uma certa probabilidade retornada pela função do mecanismo adaptativo, for atendida, o operador entra em funcionamento. Em seguida, são gerados dois pontos aleatórios x_1 e x_2 tal que $x_1 > 1$, $x_1 < x_2$, $x_2 < D$. Então, são gerados dois filhos que se dominarem seus pais, serão inseridos na população. A Figura 3 ilustra o operador de cruzamento.

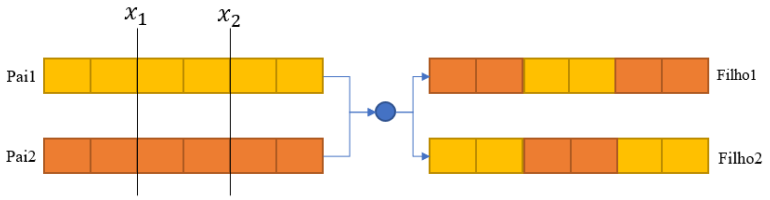


Figura 3: Representação do cruzamento ANSGA-II

4.6. Operador de mutação

No operador de mutação, para cada indivíduo, se uma condição com uma certa probabilidade retornada pela função do mecanismo adaptativo, for atendida, o indivíduo sofrerá a mutação. Neste trabalho, se uma solução sofre mutação, é gerado outro indivíduo aleatório que substituirá o indivíduo atual.

4.7. Ordenação não dominada

Conforme o trabalho de [Verma et al., 2021], neste procedimento, os indivíduos são ordenados com base na dominância de Pareto. O procedimento começa atribuindo o *rank* 1 para os indivíduos não dominados da população. Esses indivíduos são, então, removidos da população e o *rank* 2 é atribuído para os indivíduos não dominados da população restante. O procedimento segue atribuindo o *rank* i para os indivíduos não dominados, até que não tenha indivíduos restantes.

4.8. Distância de aglomeração

A distância de aglomeração é calculada estimando a densidade de soluções no entorno de uma determinada solução. É a distância média das duas solução que estão mais próximas de uma determinada solução em cada lado. Uma solução com uma maior distância de aglomeração está em uma região menos populosa. Conforme o que foi apresentado em [Verma et al., 2021], a distância de aglomeração é calculada da seguinte forma. Seja f_j^i o j-ésimo de uma função objetivo para o i-ésimo indivíduo, e f_j^{max} e f_j^{min} são os respectivos valores máximos e mínimos da j-ésima função objetivo. Então, a distância de aglomeração para o i-ésimo indivíduo é a distância média das duas soluções mais próximas em cada lado, segue a expressão matemática correspondente.

$$cd(i) = \sum_{j=1}^{k} \frac{f_j^{i+1} - f_j^{i-1}}{f_j^{max} - f_j^{min}} \tag{14}$$

onde k representa o número de funções objetivo no problema.

4.9. Operador seleção

A seleção é o processo de criação da próxima população com base na atual. Neste trabalho será usado a seleção por torneio. São selecionados dois indivíduos aleatoriamente, o que tiver o menor *rank* vence o torneio, ou se tiverem o mesmo *rank*, o que tiver maior distância de aglomeração vence o torneio. O vencedor do torneio passa para a próxima população, até que a próxima população tenha o tamanho determinado [Verma et al., 2021].

5. Experimentos Computacionais

Para avaliação do desempenho do ANSGA-II, foi realizada a aplicação do algoritmo na inst-ância PDH retirada da SNDlib. Os testes foram realizados em ambiente *windows* 10, processador Ryzen 3 2200G 3,5GHz, *quadcore*. O python 3.8 foi a linguagem de programação usada na implementação do ANSGA-II.

5.1. A rede PDH

A rede que usa a tecnologia Hierarquia Digital Plesiócrona (PDH - *Plesiochronous Digital Hierarchy*) é inspirada na realidade e foi retirada do site SNDlib.com. Conforme apresentado no trabalho [Oliveira, 2020], redes com tecnologia PDH, ainda são bastante utilizadas, principalmente nos segmentos periféricos da rede. Neste trabalho, a PDH foi escolhida por já ter sido escolhida em outros trabalhos, possibilitando a comparação dos resultados obtidos pelo ANSGA-II com outros artigos e os resultados dispostos no site SNDlib.com. A PDH contém 11 vértices, 34 links e 24 demandas, existem 3 módulos de capacidade que podem ser instaladas em cada *link*, com capacidades variando entre, 30, 480 e 1920. A Tabela 1 mostra os parâmetros de configuração da instância, a PDH pode ser encontrada no site SNDlib.com [Orlowski et al., 2006] usando esses parâmetros

Tabela 1: Características da rede

1	*Demand model*	*Undirected*
2	*Link model*	*Undirected*
3	*Link capacity model*	*Explicit Link capacities*
4	*Fixed-charge model*	*No fixed-charge cost*
5	*Routing model*	*Single path*
6	*Admissible path model*	*All Paths*
7	*Hop-limit model*	*No Hop limits*
8	*Survivability model*	*No Survivability*

O primeiro campo, trata-se do modelo de demanda da rede. O modelo de demanda que será usado neste trabalho é o não direcionado. Isso implica, que as demandas podem ser enviadas de qualquer direção. O modelo de *link* que será usado é o não direcionado, ou seja, as demandas podem fluir em qualquer direção nos *links*. Por simplicidade, neste trabalho, não adotaremos um custo pré-fixado, modelo de sobrevivência ou limite de *Hops*. A demanda será escoada por um único caminho da rede e não há caminhos pré-determinados para essas demandas. Apenas um módulo pode ser instalado por *link*, dentre várias opções.

5.2. Resultados

O ANSGA-II foi deixado em execução durante 1h, com uma população de 75 indivíduos em todos os testes. Nesta sessão, mostra-se a frente de pareto do melhor resultado adquirido e as soluções não dominadas obtidas e soluções obtidas em outros trabalhos. A Tabela 2 e 3 contém as soluções não dominadas obtidas obtidas, a soma de *Hops* foi abreviada como *SHops*. A Figura 4, mostra o comportamento do conjunto de soluções ao fim da execução do ANSGA-II. A Figura 5, mostra a topologia da solução com menor custo (Solução 3) e a Figura 6, mostra a topologia

solução com menor *SHops* (Solução 7) contendo o fluxo no *link* e a capacidade instalada, conforme a Tabela 2 e 3. A Tabela 4, expõe os resultados da biblioteca SNDlib e do trabalho de [Oliveira, 2020], todos esses resultados foram obtidos com estratégias mono-objetivo e na maioria dos casos, a soma dos *Hops* não é acessível.

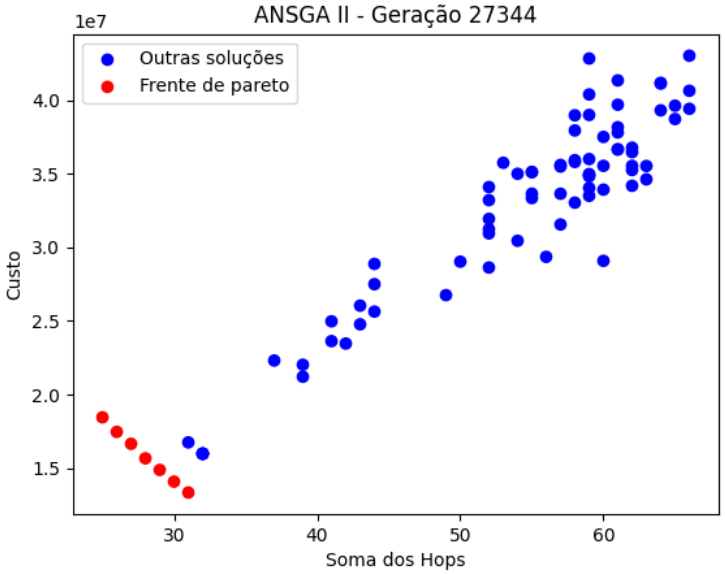


Figura 4: Frente de pareto obtida para PDH

Tabela 2: Conjunto de Soluções não dominadas (parte 1)

	Solução 1	Solução 2	Solução 3
Custo	15.672.352	14.886.846	13.351.799
SHops	28	29	31

Tabela 3: Conjunto de Soluções não dominadas (parte 2)

	Solução 4	Solução 5	Solução 6	Solução 7
Custo	16.659.308	14.089.865	17.470.314	18.458.545
SHops	27	30	26	25

Tabela 4: Soluções da biblioteca SNDlib [Orlowski et al., 2006] e [Oliveira, 2020]

	SNDlib	GA-1	GA-2	GA-3	GA-4	GA-5
Custo	14.883.708	14.765.752	12.966.484	14.495.788	14.511.654	13.785.492
SHops	48	-	-	-	-	-

5.3. Comparações

Tendo em vista as Tabelas 2, 3 e 4 apresentadas na seção anterior. Duas soluções do ANSGA-II dominam a solução da biblioteca SNDlib, porém nenhuma solução do ANSGA-II é

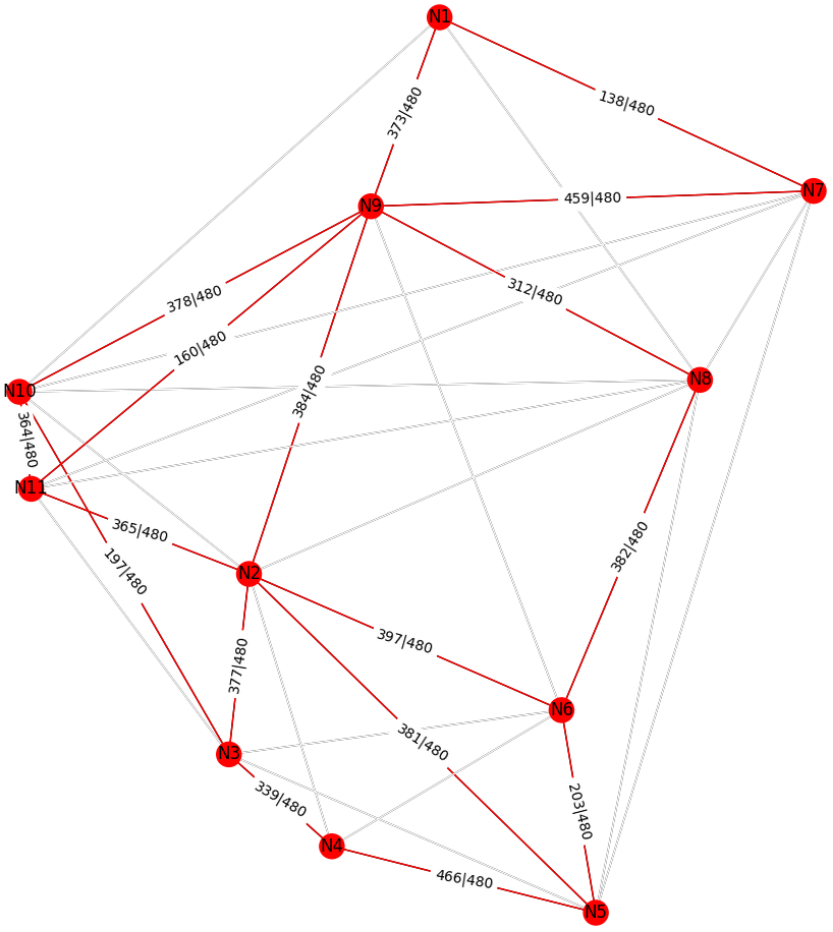


Figura 5: Topologia da solução com menor custo (Solução 3) Legenda: (Fluxo/Capacidade)

dominada pela solução SNDlib. O menor custo obtido pelo ANSGA-II (Solução 3) é inferior ao custo da solução do SNDlib com uma distancia de $10,29\%$ e a soma dos *Hops* da mesma solução é inferior à soma de *Hops* da solução SNDlib em 35%. Não é possível comparar as solucões apresentadas em [Oliveira, 2020] com o ANSGA-II em termos de dominância de pareto devido ao desconhecimento das somas de *Hops*. porém, o menor custo obtido pelo ANSGA-II tem uma diferença de $2,89\%$ em relação ao trabalho de Oliveira.

Neste trabalho, não está sendo comparado o tempo entre os algoritmos, devido ao fato de que o ANSGA-II pode encontrar novas soluções para aumentar a frente no decorrer do tempo. Por exemplo, a execução do ANSGA-II poderia ser encerrada antes de uma hora e haveriam boas soluções, porém, é provável que haveriam menos soluções na frente de pareto, ou seja, menos soluções disponíveis para os projetistas. Neste trabalho, considera-se que 1h de execução é suficientemente curto para testar a capacidade do ANSGA-II de obter uma variedade de boas soluções.

6. Conclusão e trabalhos futuros

Neste trabalho, foi implementado um NSGA-II com mecanismos adaptativos para resolver o problema de *design* de redes considerando dois objetivos. Obteve-se bons resultados em comparação com algoritmos mono-objetivo, obtendo resultados melhores que a SNDlib e muito próximos dos resultados obtidos no trabalho de [Oliveira, 2020]. Com isso, comprova-se que é

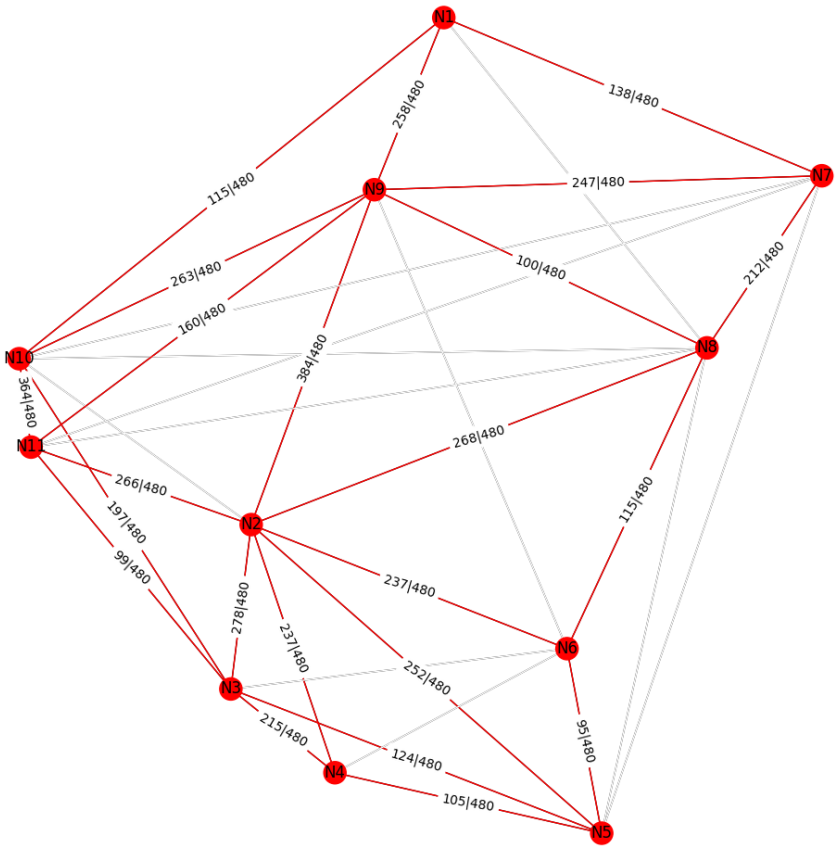


Figura 6: Topologia da solução com Soma de *Hops* (Solução 7) Legenda: (Fluxo/Capacidade)

muito vantajoso, lidar com *design* de redes de forma a otimizar vários critérios.

Outro ponto relevante a se considerar em relação ao ANSGA-II, é a diversidade de soluções. Os algoritmos de otimização multiobjetivo baseados na frente de pareto, retornam uma diversidade de soluções para o problema em questão. Isso pode ser muito útil para os projetistas, pois há uma gama de opções com diferentes equilíbrios entre os critérios. O projetista tem então uma diversidade de opções para escolher de acordo com a sua necessidade. Neste trabalho, O ANSGA-II apresenta 7 soluções para o projetista.

Os mecanismos adaptativos também trazem outra vantagem ao projetista. Um dos problemas que se enfrenta ao desenvolver algoritimos genéticos, é o de escolher os parâmetros certos para melhor convergência. No ANSGA-II o único parâmetro que precisa ser decidido, é o tamanho da população, facilitando a configuração do algoritmo para o projetista. ” Para os próximos trabalhos, planeja-se acrescentar mais critérios de otimização, como o comprimento médio da rede em termos de distância, o delay da rede, entre outros. Considera-se também, a aplicação do algoritmo inspirado em colônia de Abelhas (ABC), que tem mostrado bons resultados na resolução de outros problemas.

Este trabalho recebeu apoio financeiro do Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação (PIBITI), fornecido pelo Conselho Nacional de Desenvolvimento Científico e tecnológico (CNPq).

Referências

Fernandez, S. A., Juan, A. A., de Armas Adrián, J., Silva, D. G. e., e Terrén, D. R. (2018). Metaheuristics in telecommunication systems: Network design, routing, and allocation problems. *IEEE Systems Journal*, 12(4):3948–3957.

Kallo, C., Battiti, R., Chiasserini, C.-F., e Marsan, M. (2004). Reducing the number of hops between communication peers in a bluetooth scatternet. In *2004 IEEE Wireless Communications and Networking Conference (IEEE Cat. No.04TH8733)*, volume 1, p. 207–212 Vol.1.

Li, J., Chen, J., Xin, B., e Dou, L. (2015). Solving multi-objective multi-stage weapon target assignment problem via adaptive nsga-ii and adaptive moea/d: A comparison study. In *2015 IEEE Congress on Evolutionary Computation (CEC)*, p. 3132–3139.

Ojha, M., Singh, K. P., Chakraborty, P., e Verma, S. (2019). A review of multi-objective optimisation and decision making using evolutionary algorithms. *International Journal of Bio-Inspired Computation*, 14(2):69–84.

Oliveira, B. Q. d. (2020). Binary integer programming with bioinspired techniques for optimized planning of optical transport networks. Master's thesis, Universidade Federal de Goiás.

Orlowski, S., Pióro, M., Tomaszewski, A., e Wessäly, R. (2006). Web page. `http://sndlib.zib.de/home.action`. Acessado: 2021-06-06.

Orlowski, S., Pióro, M., Tomaszewski, A., e Wessäly, R. (2007). SNDlib 1.0–Survivable Network Design Library. In *Proceedings of the 3rd International Network Optimization Conference (INOC 2007), Spa, Belgium*. URL `http://www.zib.de/orlowski/Paper/OrlowskiPioroTomaszewskiWessaely2007-SNDlib-INOC.pdf.gz`. http://sndlib.zib.de, extended version accepted in Networks, 2009.

Verma, S., Pant, M., e Snasel, V. (2021). A comprehensive review on nsga-ii for multi-objective combinatorial optimization problems. *IEEE Access*, 9:57757–57791.

Wang, S., Zhou, Y., e Zhang, J. (2018). An improved nsga-iii approach to many-objective optimal power flow problems. In *2018 Chinese Automation Congress (CAC)*, p. 2664–2669.

Xu, W., He, S., Song, R., e Chaudhry, S. S. (2012). Finding the k shortest paths in a schedule-based transit network. *Computers Operations Research*, 39(8):1812–1826. ISSN 0305-0548. URL `https://www.sciencedirect.com/science/article/pii/S0305054810000493`. Special Issue: Advances of Operations Research in Service Industry.