

Uma Abordagem de Otimização Para o Algoritmo de Roteamento Utilizando Lógica Nebulosa

José Cleyton da Silva*, Carmelo J. A. Bastos-Filho[†], Isabella de S. Couto[†], André V. S. Xavier*, Ewerton de O. Figueirôa[‡], Danilo R. B. Araújo[‡], Joaquim F. Martins-Filho*

*Universidade Federal de Pernambuco, Recife 50740-550 Pernambuco, Brasil

Tel: +55 81 21267784, e-mail: jfmf@ufpe.br

[†]Universidade de Pernambuco, Recife 50720-001 Pernambuco, Brasil

Tel: +55 81 31847542, e-mail: carmelofilho@ieee.org

[‡]Universidade Federal Rural de Pernambuco, Recife 52171-900 Pernambuco, Brasil

Tel: +55 81 21193842, e-mail: danilo.araujo@ufrpe.br

Resumo—Este artigo propõe uma estratégia de otimização para um algoritmo de roteamento baseado em lógica nebulosa com aplicação em redes ópticas elásticas. O algoritmo de roteamento nebuloso que foi utilizado no estudo seleciona as rotas de forma dinâmica baseado em um critério de menor custo. Para o cálculo do custo da rota são consideradas métricas da camada física e de rede. A técnica de defuzzificação utilizada por esse algoritmo é a Takagi-Sugeno. Para configurar o algoritmo nebuloso se faz necessário definir os pesos das regras utilizadas no método Takagi-Sugeno e os valores dos intervalos das funções de pertinência. Essas definições são feitas, comumente, por um especialista no problema abordado. Porém, no presente trabalho, foi utilizado um algoritmo de otimização por enxames de partículas (PSO) para selecionar uma configuração otimizada baseada em simulações com as topologias escolhidas. Os resultados obtidos foram promissores em termos de probabilidade de bloqueio, demonstrando a eficácia da abordagem de otimização.

I. INTRODUÇÃO

Nos últimos anos, os estudos para o desenvolvimento das redes que utilizam tecnologia óptica estão cada vez mais intensificados. Esse investimento na área é consequência do aumento populacional e da chegada de novas tecnologias e aplicações que exigem uma maior taxa de transmissão. A utilização de redes ópticas tenta, nesse sentido, suprir essas demandas do mercado utilizando estratégias que visam reduzir o custo financeiro de sua aplicação [1]. Nas últimas décadas, a tecnologia de redes ópticas mais comumente implantada segue o modelo WDM (*Wavelength Division Multiplexing*), que utiliza canais com faixa de espectro fixo para a transmissão dos dados [2].

Com o objetivo de apresentar uma solução em eficiência espectral, as redes ópticas elásticas (EONs) apresentam uma solução promissora. Esse paradigma de rede possui canais com largura de banda flexível e transmitem dados com diferentes taxas de transmissão [3]. Essa flexibilidade espectral permite a utilização de técnicas que consideram o estado atual da camada de rede e os serviços requisitados pelos clientes [4]. Em comparação com as redes WDM, as redes elásticas conseguem utilizar de forma mais eficiente a banda espectral. Isso acontece porque nas EONs são utilizados *slots*

de frequência que ocupam uma faixa de espectro reduzida em comparação com canais WDM. Na etapa de atribuição de espectro dos *lightpaths*, um ou mais *slots* podem ser utilizados para alocar a demanda, fazendo com que a quantidade de banda desperdiçada seja minimizada [5].

Algumas restrições são comuns na gestão de espectro numa EON. Dentre essas restrições temos a continuidade e a contiguidade dos *slots*. A continuidade implica na utilização dos mesmos *slots* de frequência em todos os *links* que compõem a rota candidata. Já a restrição de contiguidade impõe que os *slots* utilizados sejam adjacentes no espectro óptico (nos casos em que é necessário utilizar mais de um slot) [6]. Para as redes elásticas, os algoritmos de roteamento e atribuição de espectro são chamados de RSA (*Routing and Spectrum Assignment*). Esses algoritmos são responsáveis por encontrar uma rota entre um par de nós origem e destino da rede e selecionar a quantidade necessária de *slots* contínuos e contíguos ao longo dos *links* da rota encontrada [7].

O problema de roteamento em redes elásticas é NP-difícil e vários elementos podem influenciar na seleção das rotas. Na literatura existem vários algoritmos que propõem soluções para o problema de roteamento de serviços em redes elásticas [5] [8]. Dentre esses algoritmos existe uma técnica publicada por Figueirôa [6] que utiliza lógica nebulosa no processo de decisão. Nesta técnica, o algoritmo seleciona a melhor rota levando em consideração três características: a ocupação dos *slots* de frequência do *link*, a ocupação dos *slots* contíguos na rota e a distância física dos *links* ópticos. Essas métricas são utilizadas no processo de roteamento para promover uma melhor distribuição do tráfego ao longo da rede e, ao mesmo tempo, selecionar uma rota que possua qualidade de transmissão (QoT - *Quality of Transmission*) suficiente para atender o serviço.

Na lógica nebulosa existem duas etapas importantes chamadas de fuzzificação e defuzzificação. Na fuzzificação, as entradas numéricas são mapeadas em valores nebulosos, já na defuzzificação é realizado o processo contrário, em que valores nebulosos são convertidos em valores reais. O processo de defuzzificação do algoritmo de roteamento nebuloso utiliza a abordagem de Takagi-Sugeno [9]. Neste caso, são determi-

nadas funções de pertinências e regras de decisão que irão compor o modelo responsável por selecionar a melhor rota de acordo com a situação atual da rede. Um especialista utiliza seus conhecimentos sobre o problema para definir os intervalos das funções de pertinência. Isso implica que o desempenho do algoritmo depende diretamente da experiência que o especialista tem com o problema. Além disso, as regras de decisão podem ser ponderadas, porém no algoritmo apresentado por Figueirôa [6] foram utilizados pesos unitários fixos.

A necessidade de um agente humano configurar determinados parâmetros do algoritmo faz com que o seu desempenho fique dependente da experiência de um especialista. Pensando nisso, este artigo propõe a utilização de uma técnica inteligente para a seleção de uma solução que maximize o desempenho da abordagem de roteamento nebuloso, utilizando para otimização o algoritmo *Particle Swarm Optimization* (PSO). Com esta abordagem, o sistema nebuloso é configurado sem a necessidade de um especialista, pois os parâmetros de configuração são assimilados através do processo inteligente. Os intervalos de todas as funções de pertinência e os pesos das regras foram otimizados de forma simultânea durante o processo proposto.

As demais partes deste artigo estão organizadas da seguinte forma: na Seção II é apresentada uma visão geral sobre o algoritmo nebuloso; na Seção III é apresentada a abordagem de otimização dos parâmetros; na Seção IV são fornecidos os detalhes sobre o arranjo experimental; na Seção V são discutidos e apresentados os resultados dos experimentos; e na Seção VI são apresentadas as conclusões do trabalho.

II. ALGORITMO NEBULOSO

Nesta seção será abordado o algoritmo baseado em lógica nebulosa utilizado para solucionar o problema de roteamento em redes ópticas elásticas. Resumidamente o algoritmo funciona da seguinte maneira: é encontrado um número k de rotas possíveis entre o par origem/destino da demanda utilizando o algoritmo de Yen [10]. Com o conjunto de rotas encontrado, o custo de cada rota é avaliado de forma individual por meio das regras de decisão definidas no algoritmo. O custo total é calculado a partir da Equação 1.

$$C_{TR} = \alpha C_{OSCR} + \beta C_{OMSR} + \gamma C_{DNR}, \quad (1)$$

em que C_{TR} é o custo total da rota, C_{OSCR} define o custo de ocupação dos *slots* contíguos da rota, C_{OMSR} é o custo médio de ocupação dos *slots* na rota e C_{DNR} é o custo da distância física normalizada da rota. Já as variáveis α , β e γ são calculadas a partir da combinação do conjunto de regras que são utilizadas no processo de defuzzificação de Takagi-Sugeno.

O cálculo da variável C_{OSCR} é realizado por meio da Equação 2.

$$C_{OSCR} = \frac{\lambda_{oT}}{\lambda_T}, \quad (2)$$

em que λ_{oT} representa a quantidade de *slots* de frequência contíguos ocupados na rota e λ_T é o número total de *slots* de frequência disponíveis por fibra.

A definição algébrica de C_{OMSR} pode ser vista na Equação 3.

$$C_{OMSR} = \frac{\sum_1^N \frac{\lambda_{oi}}{\lambda_t}}{N}, \quad (3)$$

em que λ_{oi} e λ_t representam, respectivamente, o número de *slots* de frequência ocupados na rota i e o número total de *slots* de frequência por fibra na rota. Já N representa a quantidade de fibras que compõem a rota.

O valor da variável C_{DNR} é calculado a partir da Equação 4.

$$C_{DNR} = \frac{d_k}{d_{max}}, \quad (4)$$

em que d_k é a distância física total da rota atual k e d_{max} é a distância física total da rota mais longa encontrada pelo Yen.

Na fase de fuzzificação, são definidos termos linguísticos para cada métrica de entrada considerada no algoritmo nebuloso. No artigo publicado por Figueirôa [6] foi utilizado o modelo Takagi-Sugeno, no qual as métricas podem assumir valores de pertinência dentro do estado em que são classificadas. Esses valores são utilizados nos cálculos das regras, que devolvem como resultado um valor real que pode ser ponderado de forma individual.

As funções de pertinência para as variáveis C_{OSCR} , C_{OMSR} , C_{DNR} podem ser definidas de forma manual por um especialista, que foi a abordagem utilizada por Figueirôa [6], porém esses valores podem ser otimizados por meio de simulações utilizando algoritmos inteligentes, como por exemplo, o PSO. Neste trabalho foram otimizados os intervalos das funções de pertinência e os pesos atribuídos a cada regra de decisão.

No artigo publicado por Figueirôa [6], foram utilizadas sete regras de decisão para o processo defuzzificação. Para este trabalho as regras foram mantidas. Os valores resultantes de cada regra são calculados a partir de combinações das métricas de entrada. Posteriormente, os valores resultantes do cálculo de cada regra são combinados para definir as variáveis α , β e γ . O cálculo de α , β e γ são apresentados nas equações 5, 6 e 7, respectivamente.

$$\alpha = \frac{\sum_{k=1}^3 (w_i \cdot y_k)}{\sum_{k=1}^3 w_i}, \quad (5)$$

$$\beta = \frac{\sum_{k=4}^5 (w_i \cdot y_k)}{\sum_{k=1}^3 w_i}, \quad (6)$$

$$\gamma = \frac{\sum_{k=6}^7 (w_i \cdot y_k)}{\sum_{k=1}^3 w_i}, \quad (7)$$

III. ESTRATÉGIA DE OTIMIZAÇÃO UTILIZANDO PSO

O *Particle Swarm Optimization* (PSO) é um algoritmo que utiliza a ideia do comportamento social de um bando de pássaros para resolver problemas complexos. Esse método foi proposto por Eberhart e Kennedy em 1995 [11]. O objetivo desse algoritmo é utilizar uma população de indivíduos simulada que, por meio da troca de informações, consiga encontrar

uma solução ótima em um espaço de busca. As experiências individuais e coletivas das soluções candidatas são utilizadas para definir a trajetória e a posição da partícula no espaço de busca.

As partículas do PSO são os indivíduos da população que fazem analogia aos pássaros que compõem um bando. Essas partículas exploram a região de busca e o desempenho de cada uma é avaliado por meio de uma função objetivo (*fitness*). A posição de cada partícula representa uma possível solução para o problema e é modificada a cada iteração do algoritmo [11]. A velocidade de movimentação da partícula também é atualizada. Essa atualização é feita por uma combinação do conhecimento individual da partícula e da experiência coletiva da população.

Durante a execução do algoritmo, a melhor posição que a partícula já esteve é chamada de *pbest* (*personal best*), enquanto a melhor posição dentre todas as partículas é chamada de *gbest* (*global best*). Ao atingir o critério de parada o *gbest* é considerada a melhor solução encontrada pelo enxame.

Neste trabalho, como já foi citado em seções anteriores, o objetivo foi utilizar o PSO para a otimização dos intervalos das três funções de pertinência utilizadas pelo algoritmo nebuloso e, junto a elas, otimizar os pesos das regras de decisão. Cada função de pertinência possui oito valores de intervalos que a definem. Como está apresentado na Figura 1, cada um desses valores foi nomeado por uma letra que vai de A até H. Com isso, cada função de pertinência pode ser representada por um vetor de oito posições.




Figura 1: Representação dos intervalos de uma função de pertinência.

Na configuração apresentada por Figueirôa [6], os pesos das regras eram todos unitários, o que as deixavam sempre com o mesmo poder de decisão. Neste trabalho a otimização desses pesos tem como objetivo quantificar a importância que cada regra possui no processo de decisão. Em consequência, a configuração otimizada resultará na escolha de possíveis melhores rotas. Como foram definidas sete regras de decisão, a modelagem desses pesos no PSO é feita por um vetor de sete posições. Por fim, a Figura 2 apresenta a modelagem final do vetor de posição de cada partícula do PSO utilizada nesta abordagem. Como o vetor conta com três funções de pertinência e os pesos das sete regras de decisão, a dimensão total da posição da partícula é 31.



Figura 2: Modelagem da partícula para o PSO.

IV. ARRANJO EXPERIMENTAL

A proposta deste trabalho foi verificada com base em experimentos computacionais que simulam uma rede óptica elástica em operação. O simulador utilizado para os experimentos foi o SIMTON [12], que foi modificado para dar suporte às características do problema. Ele foi usado no processo de busca do PSO para a avaliação do *fitness* de cada partícula e também durante os testes individuais das configurações obtidas, em que foi verificada a probabilidade de bloqueio em função da carga da rede. Para cada simulação foram realizadas 10^5 chamadas. Os pares fonte-destino de cada chamada foram gerados de forma pseudo-aleatória, de acordo com uma função de distribuição uniforme. As requisições de chamadas são caracterizadas como um processo de Poisson, já o tempo de duração para cada chamada é caracterizado por um processo exponencial. Para cada cenário de testes foram realizadas 30 execuções independentes e foi aplicado o teste estatístico de Wilcoxon para validar os resultados obtidos.

No processo de otimização do PSO foram utilizadas populações com 20 partículas, execuções com 100 iterações e espaços de busca de 0 à 1 para as posições. Esses parâmetros utilizados foram definidos de forma empírica baseado no tempo de convergência do algoritmo. Foi realizado um processo de busca para cada topologia de forma individual, pois as características físicas da rede influenciam diretamente na solução encontrada.

Para o treinamento e testes de configurações foram utilizadas três topologias: a NSFNet, a Pacific Bell e a Finlândia. As Figuras 3, 4 e 5 apresentam as três topologias, respectivamente. As cargas utilizadas nas simulações para cada topologia foram obtidas a partir de uma análise em que o valor da probabilidade de bloqueio atingisse valores menores que 1% com um algoritmo simples de menor caminho. Todos os *links* das redes são considerados bidirecionais. Nas simulações foram consideradas penalidades físicas (apenas lineares) e de rede. A probabilidade de bloqueio foi calculada como a razão entre as chamadas bloqueadas e o número total de chamadas.

Ao final da otimização foram encontrados os vetores solução para cada topologia. Essas informações foram transformadas em funções de pertinência e nos pesos necessários para a configuração do algoritmo nebuloso.

As simulações foram executadas em um computador com processador Intel i7 com 2,5Ghz e 6GB de RAM.




Figura 3: Topologia NSFNet.




Figura 4: Topologia PacificBell.




Figura 5: Topologia Finlândia.

V. RESULTADOS

Nesta seção, são apresentadas as soluções obtidas por meio da otimização do PSO e é feita uma comparação de desempenho em termos de probabilidade de bloqueio com a versão do algoritmo configurada pelo especialista. A Figura 6 mostra um exemplo de função de pertinência extraída do resultado do PSO para carga de 220 erlangs.

Com as soluções advindas do PSO, foram feitas as configurações do algoritmo nebuloso e o resultado dos testes foram comparados com os resultados obtidos pelo algoritmo regulado por um especialista. As Figuras 7, 8 e 9, mostram uma comparação entre o algoritmo configurado pelo especialista e pelo PSO. Nota-se que para todas as topologias a configuração obtida pelo PSO obteve taxas de probabilidade de bloqueio menores ou iguais para todas as cargas analisadas. Já a Figura 10 apresenta um comparativo entre as configurações do algoritmo em cada topologia considerando a carga em que a diferença de probabilidade de bloqueio foi maior.

Ao observar os gráficos comparativos, pode-se perceber que

NSFNet - Função de Pertinência




Figura 6: Função de pertinência OMSR.

NSFNet




Figura 7: Comparação entre a configuração do especialista X PSO para a NSFNet.

PacificBell




Figura 8: Comparação entre a configuração do especialista X PSO para a Pacific Bell.

o algoritmo conseguiu em todos os casos alguma melhora, porém a diferença não foi tão discrepante. Isso pode ter acontecido pelo fato de alguma métrica utilizada no algoritmo nebuloso não possuir tanta significância para o resultado do processo. Um estudo sobre as métricas pode ser realizado posteriormente para validar esta hipótese.

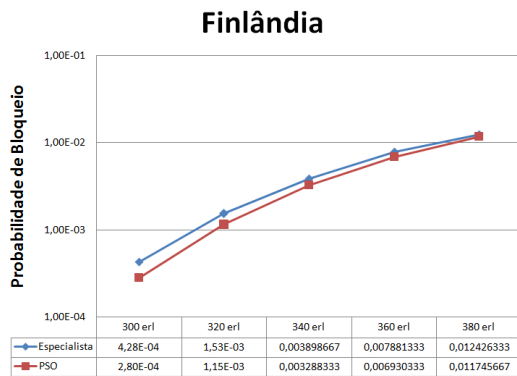


Figura 9: Comparação entre a configuração do especialista X PSO para a topologia Finlândia.

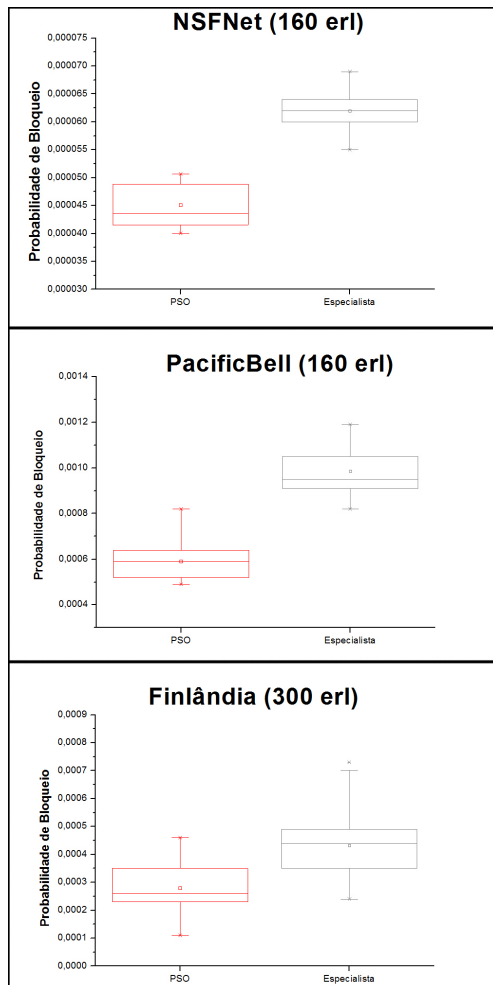


Figura 10: Boxplots comparativos entre a configuração do especialista X PSO.

VI. CONCLUSÕES

No presente trabalho foi proposta uma abordagem de otimização para o algoritmo nebuloso aplicado ao roteamento em

redes elásticas. Para isso, foi utilizado o *Particle Swarm Optimization* (PSO), que foi modelado para buscar uma solução ótima para os intervalos das funções de pertinência e os pesos das regras de decisão. O processo de otimização foi aplicado em todas as topologias e o PSO conseguiu obter soluções coerentes.

A utilização da nossa proposta se mostrou promissora, pois em todos os cenários analisados os resultados foram melhores ou iguais quando comparados com a versão padrão do algoritmo. Foi observado também, que mesmo com a otimização os resultados não foram tão expressivos. Por esse motivo, em trabalhos futuros pode-se fazer um estudo sobre o impacto que cada métrica causa no processo de seleção das rotas. Com isso, algumas métricas de maior importância poderiam ser adicionadas e outras menos significativas poderiam ser removidas.

AGRADECIMENTOS

O autores agradecem o suporte financeiro fornecido pelo CNPq, CAPES, FACEPE, UPE, UFRPE e UFPE.

REFERÊNCIAS

- [1] E. O. Figueiroa E. Lopes, E.A.O. Lima. Benefícios da otimização da eficiência espectral com a utilização de redes ópticas elásticas. *Seminário Nacional de Produção e Transmissão Energia Elétrica*, Outubro 2015.
- [2] R. Ramaswami and K. N. Sivarajan. *Optical Networks: A Practical Perspective*. Morgan Kaufmann, 3rd edition, 2010.
- [3] D. A. R. Chaves, E. F. da Silva, C. J. A. Bastos-Filho, H. A. Pereira, and R. C. Almeida. Heuristic algorithms for regenerator assignment in dynamic translucent elastic optical networks. In *2015 17th International Conference on Transparent Optical Networks (ICTON)*, pages 1–4, July 2015.
- [4] Sahar Talebi, Furqan Alam, Iyad Katib, Mohamed Khamis, Reda Salama, and George N Rouskas. Spectrum management techniques for elastic optical networks: A survey. *Optical Switching and Networking*, 13:34–48, 2014.
- [5] A.V.S. Xavier; H.A. Pereira; D.A.R. Chaves; C.J.A. Bastos-Filho; J.F. Martins-Filho; R.C. Almeida Jr. Algoritmo de roteamento baseado na continuidade de formas de conexões em redes ópticas. *Momag*, 2014.
- [6] E. O. Figueiroa, E. A. O. Lima, C. J. A. Bastos-Filho, J. C. da Silva, A. V. S. Xavier, and D. R. B. Araujo. A routing algorithm based on fuzzy logics for elastic optical networks. In *2017 IEEE 18th International Conference on High Performance Switching and Routing (HPSR)*, pages 1–6, June 2017.
- [7] A. V. S. Xavier. *Roteamento e proteção dedicada em redes ópticas usando inteligência computacional*. PhD thesis, 2016.
- [8] Y. Wang, X. Cao, and Y. Pan. A study of the routing and spectrum allocation in spectrum-sliced elastic optical path networks. In *2011 Proceedings IEEE INFOCOM*, pages 1503–1511, April 2011.
- [9] Silva A.C.O. *Classificador de Tráfego e Seleccionador de Paradigmas de Comutação para Redes Ópticas Híbridas*. Master thesis, Universidade de Brasília, 2014.
- [10] Jin Y. Yen. Finding the k shortest loopless paths in a network. *Management Science*, 17(11):712–716, 1971.
- [11] J. Kennedy and R. Eberhart. Particle swarm optimization. In *Neural Networks, 1995. Proceedings., IEEE International Conference on*, volume 4, pages 1942–1948 vol.4, Nov 1995.
- [12] D. A. R. Chaves, H. A. Pereira, C. J. A. Bastos-Filho, and J. F. Martins-Filho. Simton: A simulator for transparent optical networks. *Journal of Communication and Information Systems*, 25:1–10, 2010.