

Artificial Neural Networks to Assess Fault Tolerance of Optical Networks

Christian Lira, Jonas Freire, Pedro Araújo, Danilo R. B. de Araújo

¹Departamento de Computação - Universidade Federal Rural de Pernambuco (UFRPE)
Recife – PE – Brasil

{christian.lira,jonas.freire,pedro.araujonascimento,danilo.araujo}@ufrpe.br

Abstract. *The assessment of a network resilience is a task that requires huge computationally cost, mainly because the most popular and reliable approach is by simulating failure on edges or equipments of a network. On the other hand, machine learning techniques have been used as good surrogate models for some similar problems of performance prediction and function approximation in various application domains. This paper proposes the use of Artificial Neural Networks (ANN) to predict fault tolerance indicators in optical transport networks, using topological metrics and others network informations as ANN input. In this paper was produced a database for training based on real world deployed backbones and the results were compared with the ones provided by a discrete event simulator. Were considered simple and double failures on the edges of an optical fiber. According to the obtained results, it is possible to obtain a network failure assessment method based on ANN which is 51.050 times faster than network simulators and with a mean square error around 3×10^{-3} .*

Resumo. *Avaliar a resiliência de redes é uma tarefa computacionalmente custosa, visto que o método mais confiável e popular para este tipo de análise é por meio de simulações de falhas em enlaces ou em equipamentos da rede. Por outro lado, técnicas de aprendizagem de máquina tem sido usadas como bons substitutos para problemas semelhantes de predição de desempenho e aproximação de funções em geral em diversos domínios de aplicação. Este artigo propõe o uso de Redes Neurais Artificiais (RNA) para predizer o nível de tolerância a falhas de enlaces de fibra óptica em redes de transporte, usando métricas topológicas e outras informações da rede como entrada da RNA. Neste trabalho foi produzida uma base de dados para treinamento derivada de redes ópticas implantadas atualmente e os resultados foram comparados com um simulador de eventos discretos usado em trabalhos anteriores. Foram consideradas falhas simples e duplas nos enlaces de fibra óptica. De acordo com os resultados obtidos, é possível obter um método de avaliação de falhas de redes baseado em RNA que é 51.050 vezes mais rápido do que as simulações tradicionais e que apresenta um erro médio quadrático em torno de 3×10^{-3} .*

1. Introdução

A demanda por serviços de telecomunicações de alta qualidade tem aumentado de forma significativa nos últimos anos (*Internet Growth Statistics*, 2019). Estas demandas ocorrem devido ao aumento do número de aplicações na Internet, como transmissão de vídeo em

tempo real e sob demanda, uso de redes sociais, transferência de dados, e assim por diante. Atualmente, a tecnologia que mais vem sendo utilizada para suportar as elevadas taxas de transmissão são as redes ópticas (Ramaswami, Sivarajan, & Sasaki, 2009).

A melhoria da eficiência dos sistemas de redes ópticas é continuamente alcançada devido aos avanços em diversas áreas de pesquisa, como: pesquisas sobre novos dispositivos ópticos (de Andrade Barboza, Bastos Filho, & Martins Filho, 2019), avanços em roteamento e eficiência espectral (Figueirôa et al., 2017), proposição de novos algoritmos para análise e planejamento de redes ópticas (De Araújo, Bastos-Filho, & Martins-Filho, 2015), dentre outras. Por outro lado, o planejamento de redes ópticas deve considerar diversos aspectos práticos e muitas vezes conflitantes, como a probabilidade de bloqueio da rede, o custo financeiro, o gasto energético, a resiliência/robustez da rede, e assim por diante. Abordagens recentemente propostas em planejamento de redes consideram metaheurísticas de otimização multiobjetivas para obter projetos de redes que minimizem os objetivos considerados (De Araújo et al., 2015). Um dos desafios destas abordagens de otimização iterativas é obter medidas de desempenho de rede com baixo custo computacional, visto que milhares de potenciais soluções são avaliadas em um processo de otimização global. Neste sentido, Araújo *et al.* (de Araujo, Bastos-filho, & Martins-filho, 2015) propuseram modelos alternativos para estimativa de probabilidade de bloqueio com base em técnicas de aprendizagem de máquina e os resultados forneceram uma diminuição de 7500 vezes de tempo de processamento quando o modelo substituto é comparado com simulações de rede. Araújo *et al.* (Araújo, de Barros, Bastos-Filho, & Martins-Filho, 2017) estudaram a aplicação de abordagem semelhante para aproximar métricas de robustez de redes complexas relacionadas com falhas em nós terminais. Contudo, não há estudos semelhantes para proposição de modelos alternativos para prever a resiliência de redes ópticas sujeitas a falhas nos enlaces de fibra óptica, que é um tipo de falha muito comum nos sistemas implantados atualmente.

Portanto, com base em estudos anteriores sobre métodos alternativos para prever o desempenho futuro de redes (de Araujo et al., 2015), (Araújo, Bastos-Filho, & Martins-Filho, 2015), (Araújo et al., 2017), este artigo propõe o uso de Rede Neural Artificial (RNA) para prever a capacidade de redes ópticas de longa distância em resistir a falhas simples e duplas em enlaces de fibra óptica. O estudo compreendeu a criação de uma base de dados (*dataset*) e avaliação da melhor arquitetura de RNA para esta tarefa. Os resultados foram comparados com a resposta do simulador de redes ópticas SIMTON. Com base nos avanços obtidos nesse estudo, o método alternativo proposto poderá ser usado futuramente em algoritmos de otimização como função de *fitness* alternativa para aferição de resiliência da rede. O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta uma fundamentação teórica sobre os temas relacionados ao trabalho, como estudos sobre resiliência de redes, métricas topológicas e métodos para regressão. A Seção 3 detalha a metodologia usada no trabalho. A Seção 4 apresenta e discute os resultados. A Seção 5 apresenta as conclusões e sugestões para trabalhos futuros.

2. Fundamentação Teórica

2.1. Sobrevivência de Redes

A resiliência contra falhas é um importante requisito para a maioria das redes de alta capacidade. Como as redes de transporte ópticas carregam muitos dados agregados, os

danos causados por uma falha em *backbone* são ainda mais severos. A quebra de um único cabo de fibra óptica pode desconectar milhões de usuários e resultar em milhões de dólares em perdas financeiras (Ramaswami et al., 2009).

Uma conexão é frequentemente roteada por muitos nós em uma rede, de modo que falhas podem ocorrer em quaisquer equipamentos dos nós da rota ou nos enlaces ópticos. A capacidade de sobrevivência de uma rede está relacionada com a habilidade desta rede continuar funcionando mesmo após uma falha. Essa característica está relacionada com a presença de rotas redundantes que são usadas quando a falha ocorre. Em geral, clientes de uma rede óptica estabelecem um contrato de uso e escolhem uma dentre várias classes de serviço com diferentes níveis de tolerância a falhas. Quando um cliente possui uma rota de trabalho e uma rota redundante que permanece ativa durante todo o tempo, é dito que o serviço é protegido (1 + 1). Quando um cliente possui uma rota de trabalho e uma rota redundante que é acionada apenas em casos de falhas, é dito que o serviço é restaurável (1 + R). Um cliente pode contratar simultaneamente o serviço de proteção e restauração (1 + 1 + R). Uma das principais diferenças práticas entre o serviço "1 + R" e o serviço "1 + 1" é que o procedimento de restauração exige um tempo de descobrimento e comutação na ordem de 60 ms. Portanto, há um compromisso entre custo financeiro e nível de sobrevivência para as diversas classes de serviço (Ramaswami et al., 2009).

2.2. Aferição da Capacidade de Sobrevivência de Redes

Para prever a capacidade de sobrevivência das redes é comum o uso de simuladores de rede que consideram eventos de falhas ou mesmo o uso de indicadores próprios que quantificam rotas redundantes e outros aspectos relacionados com resiliência. Neste artigo será utilizado o simulador SIMTON (Chaves, Pereira, Bastos-Filho, & Martins Filho, 2010) como *benchmarking* para aferição da capacidade de sobrevivência das redes estudadas. O SIMTON é um simulador de redes ópticas que modela um tráfego dinâmico na rede no qual a probabilidade de chegada de novas requisições seguem uma distribuição de Poisson. A cada evento do simulador são consideradas falhas simples e duplas em enlaces de fibra óptica. No caso de falha simples, um único enlace é falhado e as conexões que passam por o enlace falhado são roteadas para outro caminho. No caso de falhas duplas, dois enlaces são falhados em sequência e as rotas novamente tentam ser restauradas. A medida de sobrevivência está relacionada com o percentual de demandas de clientes que conseguiram ser recuperadas.

As simulações de falhas são computacionalmente custosas e diversos indicadores baseados em expressões analíticas ou cálculos simples estão disponíveis na literatura. A subseção a seguir detalha algumas dessas métricas derivadas da teoria das redes complexas (Lewis, 2009).

2.2.1. Métricas Topológicas Relacionadas à Resiliência

Para obtenção de métricas topológicas relacionadas à resiliência é útil modelar as redes do mundo real como grafos (de Araujo et al., 2015) $G = (N, L)$, no qual N e L são os nós e vértices dos grafos, respectivamente. A quantidade de nós e enlaces no grafo, por sua vez, são dados por $n = |N|$ e $l = |L|$. Com base no grafo da rede são derivados alguns indicadores simples e diretos e outros mais complexos que possuem correlação com a resiliência das redes. Conceitos básicos incluem:

- A *conectividade natural* é uma forma de mensurar a redundância de caminhos alternativos como o número dimensionado de passeios fechados de todos os tamanhos baseado no grafo espectral (Wu, Barahona, Yue-Jin, & Deng, 2010);
- A *conectividade algébrica* é o segundo menor autovalor de uma matriz laplaciana de uma rede. Se o valor for acima de 0 a rede é um grafo conectado e a magnitude do valor possui correlação positiva com tolerância a falhas em enlaces (Lewis, 2009);
- A *DFT da entropia laplaciana* é a transformada discreta de Fourier dos autovalores de uma matriz laplaciana de uma rede. Está relacionada com a forma como os enlaces estão dispostos (topologia em malha, estrela, etc) (de Araujo et al., 2015);
- O *grau de hub* consiste na quantidade de links que pertence ao nó mais conectado da rede (Lewis, 2009).

Além das medidas simples citadas, uma noção de resiliência de um grafo pode ser expressa pela redundância de caminhos entre dois nós e por estimativas mais confiáveis dessa redundância. Pode-se formalmente considerar redundância como o número de rotas alternativas de diferentes tamanhos para todos os pares de nós de uma rede. É uma medida difícil de ser calculada de forma exata e por isso métricas como *Indicador de Robustez* (Derrible & Kennedy, 2010) foram criadas para estimar o número de rotas alternativas. Outras métricas para estimar a resiliência da rede baseando-se no espectro do grafo, já foram propostas como *Resistência Efetiva* (Mieghem, 2010) e *Condutância de Grafos* (Derrible & Kennedy, 2010). Em (Derrible & Kennedy, 2010) a resiliência da rede é quantificada baseando-se no número de rotas alternativas na topologia dividido pelo número total de nós do grafo. Enquanto que em (Wu et al., 2010) é proposto medir a redundância de rotas alternativas como o número escalado de passeios fechados de todos os tamanhos, baseados no espectro do grafo, chamado de conectividade natural.

2.3. Métodos de Regressão

Em um problema de regressão típico, geralmente há uma medida de saída quantitativa (como percentual de falhas recuperáveis da rede óptica) ou saída categórica (como qualidade de serviço aceitável ou não para um enlace óptico) e estas saídas devem ser corretamente determinadas na saída do método regressor.

Modelos lineares tem sido usados nos últimos 30 anos com alternativas para regressão. Dado um vetor p de entradas $X_T = (X_1, X_2, \dots, X_p)$, o objetivo é prever a saída \hat{Y} usando um modelo linear por

$$\hat{Y} = \hat{\beta}_0 + \sum_{j=1}^p X_j \hat{\beta}_j, \quad (1)$$

em que $\hat{\beta}$ é um vetor de pesos para X_T , $\hat{\beta}_j$ é o peso de X_j e o termo $\hat{\beta}_0$ é o *bias*. Há muitos métodos para treinamento de um modelo linear que é ajustado para uma determinada base de treinamento, mas o mais popular é o método dos mínimos quadrados. Nessa abordagem, os coeficientes $\hat{\beta}_j$ devem ser obtidos de modo a minimizarem a soma do erro médio quadrático (*EMQ* ou *MSE - Mean Squared Error*),

$$MSE(\beta) = \sum_{i=1}^N (y_i - x_i^T \hat{\beta})^2. \quad (2)$$

em que N é o número de amostras ou padrões, e x_i^T é o vetor de entrada para o padrão i . Modelos lineares são simples e podem superar modelos não lineares em situações peculiares, como em situações com poucos casos, baixa taxa de erro ou dados esparsos (Hastie, Tibshirani, & Friedman, 2008).

Contudo, métodos de regressão também podem estabelecer relações não lineares de características derivadas das entradas. Redes Neurais Artificiais (RNA) tem sido amplamente usadas para este propósito em vários domínios de aplicação. Uma RNA possui um conjunto de pesos que podem ser ajustados para aferir a saída considerando uma dada base de treinamento. A medida de erro médio quadrático é frequentemente usada em abordagens de gradiente descendente para o processo de ajuste. Dentre os métodos populares para o processo de treinamento da RNA podem ser citados o back-propagation and Levenberg-Maquardt (LM) (Haykin, 2010). Além disso, estudos na área também aplicam metaheurísticas de otimização global para o processo de ajuste dos pesos como otimização por enxame de partículas e evolução diferencial (Zhao et al., 2013).

3. Metodologia

O objetivo deste trabalho é propor um método alternativo para aferição da resiliência de redes com baixo custo computacional. Mais especificamente, o estudo consiste em usar uma Rede Neural Artificial (RNA) para aproximar o percentual de demandas recuperáveis que é fornecido pelo simulador de redes ópticas SIMTON. Neste estudo foi utilizado o popular modelo *Multilayer Perceptron* (MLP).

A arquitetura geral da RNA contemplará uma camada de entrada, com um vetor relacionado com métricas topológicas simples (como as descritas na Seção 2.2), uma camada escondida e uma camada de saída com dois neurônios (para estimativa de ambas as falhas simples e duplas).

Na Figura 1 podemos observar a arquitetura da MLP, na primeira camada as entradas X_0, X_1, \dots, X_5 correspondem respectivamente, aos parâmetros já normalizados: Número de Links; Número de Nós; DFT da Entropia Laplaciana; Conectividade Natural; Conectividade Algébrica; Grau de Hub. Conectados com todos os neurônios da camada oculta, e por fim estes conectados aos neurônios Y_0, Y_1 da camada de saída, no qual os seus resultados variam no intervalo $[0, 1]$, que são, respectivamente, os valores para falhas simples e duplas daquela rede óptica especificada na entrada.

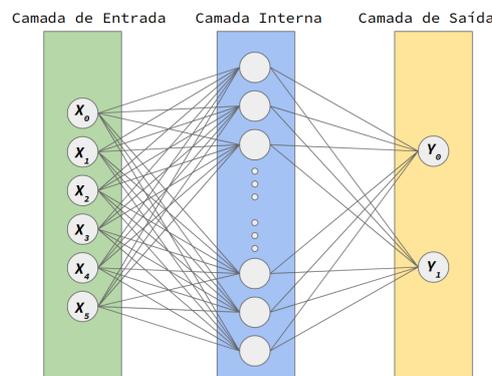


Figura 1. Arquitetura da RNA

Para viabilizar o treinamento da RNA, foi necessária a construção de uma base de dados de treinamento. A base considerou 3000 padrões topológicos que são variantes de uma rede óptica em operação na Alemanha, a saber, a rede HSE Medianet de 18 nós (Knight, Nguyen, Falkner, Bowden, & Roughan, 2011) apresentada na Figura 3. As características topológicas, por sua vez, foram usados para compor o vetor de característica usado como entrada para a RNA. Sendo assim, com o intuito de auxiliar a RNA a reconhecer os padrões nos dados e conseqüentemente obter resultados confiáveis, os dados foram normalizados, de acordo com a equação:

$$x'_i = \frac{x_i - \min x}{\max x - \min x}, \quad (3)$$

Onde x_i representa o valor de um atributo presente na base. $\min x$ e $\max x$ representam o menor e o maior valor desse mesmo atributo, respectivamente.

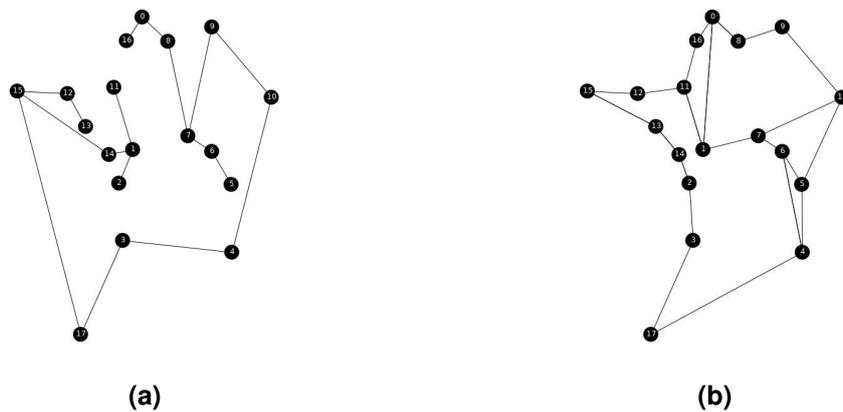


Figura 2. Variações de topologias relacionadas com as posições de nós originais da rede.

A Figura 2 ilustra dois padrões da base de treinamento que são variações da rede HSE Medianet original. Percebe-se que as variações nos padrões ocorrem devido à presença/ausência de diferentes enlaces de fibra óptica.



Figura 3. Rede HSE Medianet original.

Para obtenção do percentual de demandas recuperáveis destas 3000 variações topológicas (saída esperada da RNA), foi utilizado o simulador SIMTON (Chaves et al., 2010). A simulação de uma topologia da base de treinamento considerou todas as possibilidades de falhas simples e duplas.

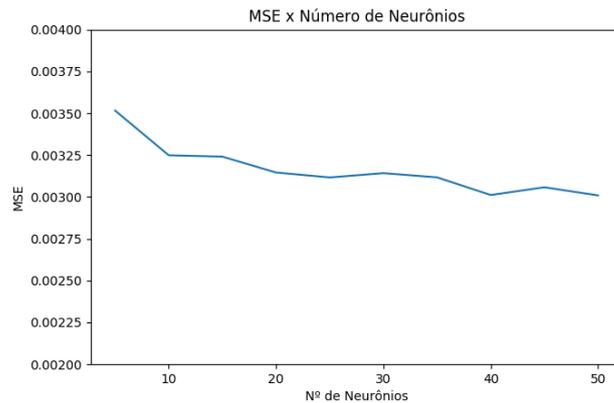
Portanto, em linhas gerais, a metodologia consistiu no seguinte:

1. Criação e normalização de um conjunto de dados para treinamento da RNA, através da simulação de falhas simples e duplas, utilizando o SIMTON (Chaves et al., 2010), da topologia HSE Medianet Fig. 3.
2. Treinamento da RNA utilizando uma camada oculta, com diferentes quantidade de neurônios, especificamente, 5 à 50 neurônios variando de 5 em 5, ou seja, [5, 10, 15, ..., 45, 50], avaliando o MSE. A entrada para a RNA consistiu nas seguintes métricas:
 - (a) Número de Links;
 - (b) Número de Nós;
 - (c) DFT da Entropia Laplaciana;
 - (d) Conectividade Natural;
 - (e) Conectividade Algébrica;
 - (f) Grau de Hub.
3. Avaliação da RNA treinada sobre o conjunto de testes.

Para avaliar esta proposta a base de 3000 padrões foi dividida em dois conjuntos, o de treinamento e de teste, com proporção de 75 % e 25 %, respectivamente. Dos 75% do conjunto de treinamento, 25 % foi usado como conjunto de validação. Como mencionado, foi utilizada uma rede MLP. A função de ativação da camada escondida foi a ReLU (Hahnloser, Sarpeshkar, Mahowald, Douglas, & Seung, 2000). A função ReLU foi escolhida pois apresentou melhores resultados dentre as funções testadas. Um outro ponto é a sua simplicidade de ser calculada pelo computador, isso faz com que o treino e execução do modelo sejam mais rápidos quando usam esta função na sua camada escondida (Glorot, Bordes, & Bengio, 2011). Outras duas características que contribuíram para utilização da ReLU foram o fato dela não sofrer o problema do *Vanishing Gradient* e por ser esparsamente ativada (Ian J. Goodfellow, 2016). Para a camada de saída, a função Sigmoid foi usada como função de ativação. Como otimizador da RNA foi usado o Adam, que é um algoritmo para a otimização baseada em gradiente de primeira ordem de funções objetivas estocásticas (Kingma & Ba, 2014). Para cada quantidade de neurônios na camada escondida, o treinamento ocorreu ao longo de 500 épocas repetidas 10 vezes cada. Como métrica de avaliação das saídas foi utilizado o MSE.

4. Resultados

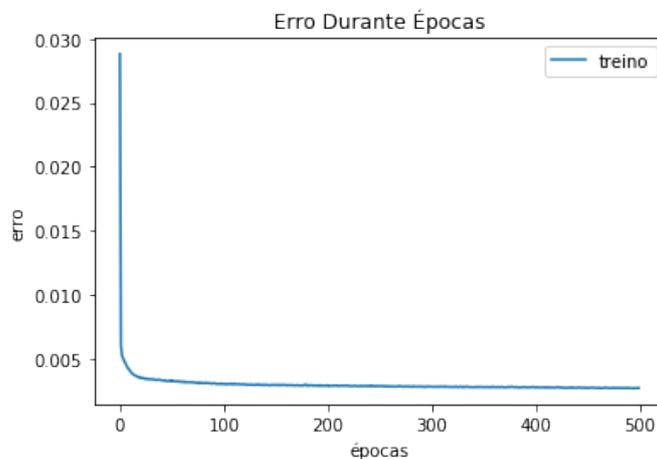
A definição da arquitetura de RNA para o problema considerado contemplou o estudo da quantidade de neurônios na camada escondida que melhor aproxime a base de dados utilizada. A Figura 4a apresenta a variação do erro de acordo com o número de neurônios presentes na camada escondida. É possível perceber que a melhor arquitetura, considerando o erro, é encontrada entre 40 e 50 neurônios na camada escondida, variando entre 3.00×10^{-3} e 3.05×10^{-3} . Portanto, as próximas análises consideram uma arquitetura de RNA com 45 neurônios na camada escondida.



(a) MSE vs. N^o de neurônios.

Figura 4. Relação entre MSE e número de neurônios na camada escondida.

A Figura 5a apresenta a variação do erro vs. épocas para uma RNA de 45 neurônios. É possível observar que o gráfico converge rapidamente sobre o conjunto de treino entre as épocas 0 a 100 e vai melhorando de maneira contínua. Para obter o número adequado de épocas para o treinamento do modelo e evitar o *overfitting*, foi usada a técnica *Early-Stopping*.



(a) Perdas x Épocas

Figura 5. Relação entre perda e épocas utilizando 45 neurônios na camada escondida.

Na Figura 6 podemos observar o momento em que o *overfitting* começa a acontecer na rede. Enquanto o conjunto de treino continua melhorando, o erro sobre o conjunto de validação começa a piorar. Também foi considerada uma comparação em nível sistêmico de quão próximo ao simulador a rede neural classificou a resiliência das redes ópticas.

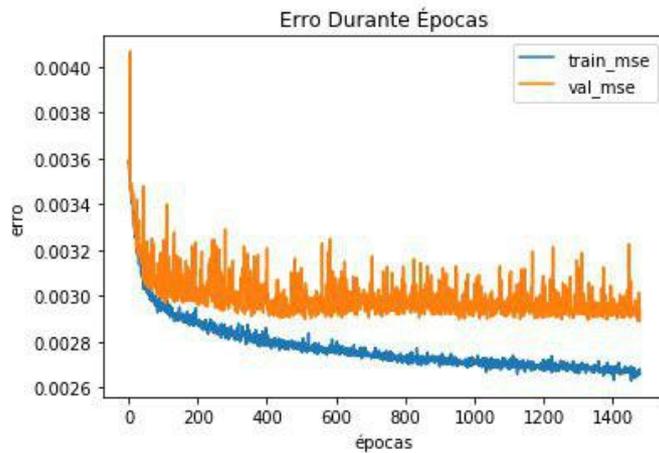


Figura 6. Erro sobre o conjunto de validação durante épocas do treinamento

A Figura 7 apresenta o comparativo entre a RNA e o SIMTON na classificação da resiliência das redes para falhas simples. A Figura 7a apresenta o comparativo para todos os padrões de teste e a Figura 7b fornece uma ampliação de uma área do gráfico para uma melhor inspeção visual. É possível perceber que o modelo de RNA com 45 neurônios na camada escondida oferece excelente aproximação para falhas simples.

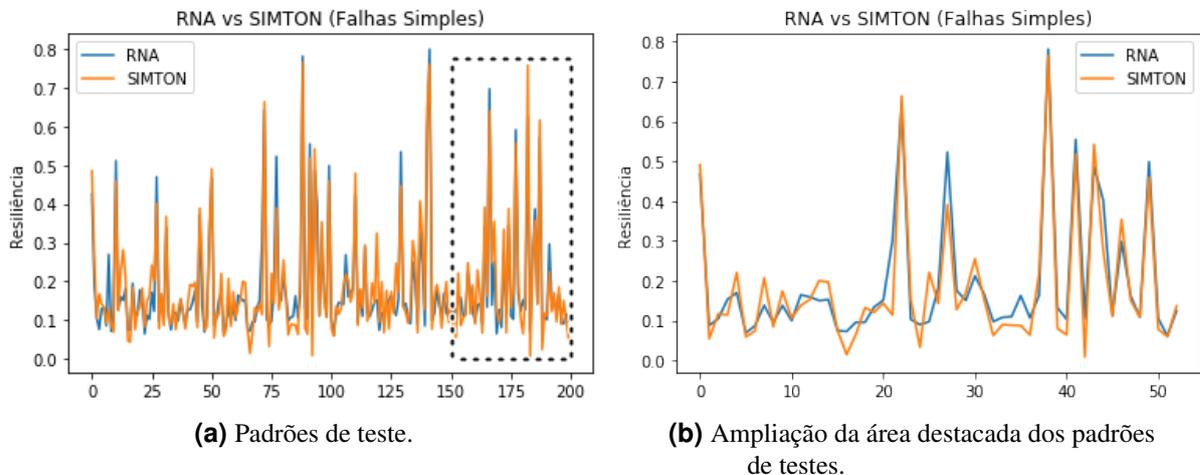
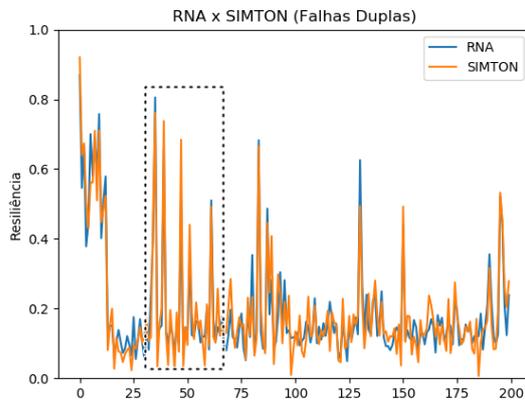
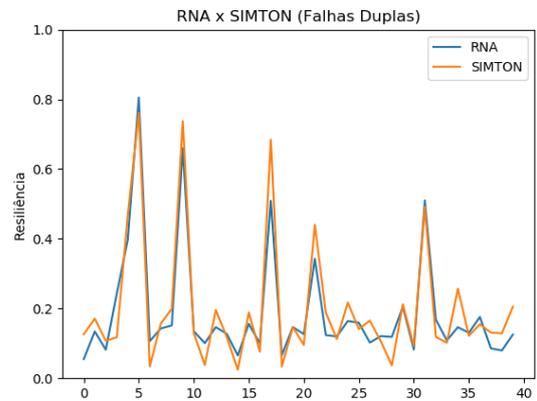


Figura 7. Comparação para falhas simples: RNA X SIMTON.

A Figura 8 apresenta o mesmo comparativo entre a RNA e o SIMTON na classificação da resiliência das redes, mas agora para falhas duplas. A Figura 8a apresenta o comparativo para todos os padrões de teste e a Figura 8b fornece uma ampliação de uma área do gráfico para uma melhor inspeção visual. É possível perceber que o modelo de RNA com 45 neurônios na camada escondida também oferece excelente aproximação para falhas duplas. Vale a pena destacar que a avaliação de falhas duplas em uma rede com maior quantidade de nós e, potencialmente maior quantidade de enlaces, provavelmente iria oferecer uma resposta a falhas duplas com valores mais próximos de 1, visto que novas rotas alternativas iriam emergir na rede óptica para suportar a segunda falha.



(a) Padrões de teste



(b) Ampliação da área destacada dos padrões de testes.

Figura 8. Comparação para falhas duplas: RNA X SIMTON.

A última e uma das mais importantes avaliações do estudo foi em relação ao tempo médio para classificar a resiliência de uma rede em ambas as abordagens. Conforme já explicitado, os simuladores de rede apresentam elevado custo computacional e a proposição de um modelo alternativo para aferição de resiliência possui como requisito importante o baixo custo computacional e conseqüentemente pequeno tempo de resposta em situações práticas. Com base nos estudos realizados, o SIMTON levou em média aproximadamente 44382 ms para aferir a resiliência de uma rede em termos de percentual de demandas restauradas em falhas simples e duplas. O modelo proposto baseado em RNA levou em média $0,86939\text{ ms}$ para obter a mesma estimativa. Portanto, foi obtido uma abordagem que é 51.050 vezes mais rápida do que o simulador de redes e com um erro que é compatível com aplicações práticas de engenharia. O treinamento da rede neural levou em média 142 s .

5. Conclusão

Este artigo propõe o uso de RNA para aferir a resiliência de redes ópticas sujeitas a falhas simples e duplas nos enlaces de fibra óptica. O estudo contemplou o desenvolvimento de uma base de dados de treinamento derivada de uma rede de transporte óptica Alemã e comparou os resultados com os que foram obtidos por um simulador de redes ópticas (SIMTON). De acordo com os resultados obtidos, é possível obter um método de avaliação de falhas de redes baseado em RNA que é 51.050 vezes mais rápido do que as simulações tradicionais e que apresenta um erro médio quadrático em torno de $3 \cdot 10^{-3}$. A abordagem proposta poderá ser usadas em ferramentas de inovação da indústria de telecomunicações e como parte integrante da avaliação de desempenho em ferramentas de planejamento e otimização de redes. Estudos futuros devem investigar a vantagem no uso de outras técnicas de aprendizagem de máquina para a tarefa de regressão e aplicar a mesma metodologia em cenários diferentes relacionados com um conjunto mais amplo de variações na quantidade e posição dos nós terminais da rede óptica. Além disso, podem ser considerados cenários com demandas de clientes heterogêneas, que precisam de diferentes classes de serviço de proteção.

6. Agradecimentos

Os autores agradecem o apoio financeiro fornecido pela UFRPE e CNPq.

Referências

- Araújo, D. R. B., Bastos-Filho, C. J. A., & Martins-Filho, J. F. (2015, July). Artificial neural networks to estimate blocking probability of transparent optical networks: A robustness study for different networks. In *2015 17th international conference on transparent optical networks (icton)* (p. 1-4). doi: 10.1109/ICTON.2015.7193693
- Araújo, D. R. B., de Barros, G. H. P. S., Bastos-Filho, C. J. A., & Martins-Filho, J. F. (2017, Nov). Surrogate models assisted by neural networks to assess the resilience of networks. In *2017 IEEE Latin American Conference on Computational Intelligence (La-CCI)* (p. 1-6). doi: 10.1109/LA-CCI.2017.8285704
- Chaves, D., Pereira, H., Bastos-Filho, C., & Martins Filho, J. (2010, 04). Simton: A simulator for transparent optical networks. *Journal of Communication and Information Systems*, 25, 1-10. doi: 10.14209/jcis.2010.1
- de Araujo, D. R. B., Bastos-filho, C. J. A., & Martins-filho, J. F. (2015, May). Methodology to obtain a fast and accurate estimator for blocking probability of optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 7(5), 380-391. doi: 10.1364/JOCN.7.000380
- de Andrade Barboza, E., Bastos Filho, C. J., & Martins Filho, J. F. (2019). Adaptive control of optical amplifier operating point using voa and multi-objective optimization. *Journal of Lightwave Technology*.
- De Araújo, D. R., Bastos-Filho, C. J., & Martins-Filho, J. F. (2015). An evolutionary approach with surrogate models and network science concepts to design optical networks. *Engineering Applications of Artificial Intelligence*, 43, 67–80.
- Derrible, S., & Kennedy, C. (2010, 09). The complexity and robustness of metro networks. *Physica A: Statistical Mechanics and its Applications*, 3678-3691. doi: 10.1016/j.physa.2010.04.008
- Figueirôa, E., Lima, E., Bastos-Filho, C. J., da Silva, J., Xavier, A. V., & Araújo, D. R. (2017). A routing algorithm based on fuzzy logics for elastic optical networks. In *2017 IEEE 18th International Conference on High Performance Switching and Routing (HPSR)* (pp. 1–6).
- Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep sparse rectifier neural networks. In *Proceedings of the fourteenth international conference on artificial intelligence and statistics* (pp. 315–323).
- Hahnloser, R. H., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J., & Seung, H. S. (2000). Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *Nature*, 405(6789), 947.
- Hastie, T., Tibshirani, R., & Friedman, J. (2008). *The elements of statistical learning*. Springer.
- Haykin, S. (2010). *Neural networks and learning machines* (3rd ed.). PHI Learning Private Limited.
- Ian J. Goodfellow, A. C., Yoshua Bengio. (2016). *Deep learning*. Cambridge, MA, USA: MIT Press.
- Internet growth statistics*. (2019). Retrieved from

<https://www.internetworldstats.com/emarketing.htm> (Acessado em 27/08/2019)

- Kingma, D. P., & Ba, J. (2014). *Adam: A method for stochastic optimization*. Retrieved from <http://arxiv.org/abs/1412.6980>
- Knight, S., Nguyen, H. X., Falkner, N., Bowden, R., & Roughan, M. (2011). The internet topology zoo. *IEEE Journal on Selected Areas in Communications*, 29(9), 1765–1775.
- Lewis, T. G. (2009). *Network science - theory and applications*. John Wiley & Sons.
- Mieghem, P. v. (2010). *Graph spectra for complex networks*. Cambridge University Press. doi: 10.1017/CBO9780511921681
- Ramaswami, R., Sivarajan, K., & Sasaki, G. (2009). *Optical networks: a practical perspective*. Morgan Kaufmann.
- Wu, J., Barahona, M., Yue-Jin, T., & Deng, H.-Z. (2010, 07). Natural connectivity of complex networks. *Chinese Physics Letters*, 27, 078902. doi: 10.1088/0256-307X/27/7/078902
- Zhao, Z., Feng, X., Wei, F., Wang, S., Cao, M., & Hou, Z. (2013). Optimized neural network ensemble by combination of particle swarm optimization and differential evolution. *Advances in Neural Networks*, 7951, 367-374. Retrieved from http://dx.doi.org/10.1007/978-3-642-39065-4_45 doi: 10.1007/978-3-642-39065-4_45