

Estimação Precisa da Qualidade de Transmissão com Redes Neurais Profundas para Sistemas Ópticos Densos

João Vitor Araujo Garcês, Igor Monteiro Moraes e Diogo Mattos

Resumo—O advento de novas tecnologias e aplicações de Internet tem aumentado a necessidade de um transporte de dados de alta taxa de transmissão e confiável. Redes ópticas DWDM utilizam métricas de Qualidade de Transmissão (QoT), como a Relação Sinal-Ruído Generalizada (GSNR), para o provisionamento de canais. Esse parâmetro requer uma previsão analítica computacionalmente custosa. Assim, este artigo propõe um modelo de redes neurais profundas para estimar a Relação Sinal-Ruído Generalizada com precisão e rapidez. O modelo é validado através de simulações, que por sua vez são validadas com dados de uma rede real em operação. Os resultados mostram um erro absoluto percentual menor que 0,54% entre a estimativa obtida pelo modelo proposto e o valor simulado.

Palavras-Chave—Redes neurais profundas, predição da GSNR, redes ópticas, OSNR.

Abstract—The advent of new Internet technologies and applications has increased the need for high-speed and reliable data transport. DWDM optical networks use Transmission Quality (QoT) metrics, such as Generalized Signal-to-Noise Ratio (GSNR), for channel provisioning. This parameter requires computationally expensive analytical prediction. Thus, this article proposes a model of deep neural networks to estimate the Generalized Signal-to-Noise Ratio accurately and quickly. The model is validated through simulations, which in turn are validated with data from a real network in operation. The results show an absolute percentage error of less than 0.54% between the estimation obtained by the proposed model and the simulated value.

Keywords—Deep Neural Network, GSNR prediction, optical networks, OSNR.

I. INTRODUÇÃO

As novas tecnologias e arquiteturas de transmissão de dados demandam uma rede de transporte de dados robusta e de alta taxa de transmissão, sendo a tecnologia de multiplexação densa por divisão de comprimento de onda (*Dense Wavelength Division Multiplexing* – DWDM) amplamente utilizada para esse propósito [1]. A Qualidade de Transmissão (*Quality of Transmission* – QoT) possui um conjunto de parâmetros que mostram a degradação do sinal óptico e é afetada por diversos fatores, lineares e não lineares. Uma das métricas mais importantes de QoT é a Relação Sinal-Ruído Generalizada (*Generalized Signal Noise Ratio* – GSNR) [2], uma generalização da métrica de relação sinal-ruído. Com isso,

J.V.A. Garcês, I.M. Moraes e D.M.F. Mattos Diogo Mattos, Laboratório MídiaCom (TET/IC/UFF), Universidade Federal Fluminense, Niterói-RJ, e-mail: joaogarcês@id.uff.br; igor@ic.uff.br; menezes@midia.com.uff.br. Este trabalho foi realizado com recursos do CNPq, CAPES, FAPERJ e RNP, e Prefeitura de Niterói/FEC/UFF (Edital PDPA 2020).

a necessidade de se ter ferramentas que possam estimar a GSNR é de grande importância, tanto no momento do projeto, implantação, quanto na gerência das redes ópticas DWDM [3].

Padrão da fibra, atenuação, dispersão cromática, dispersão de polarização, perdas por reflexão, emendas e interferência devido a ruído amplificado espontâneo (*Spontaneous Emission Noise* – ASE) são alguns dos efeitos lineares que impactam a qualidade do sinal óptico. Além disso, existem os efeitos não lineares, como o espalhamento de Raman, mistura de quatro ondas (*Four-Wave Mixing* – FWM) e diafonia ou *crosstalk*, que são efeitos de natureza complexa e muito mais difíceis de se prever [2], [4]. A alocação de canais em sistemas DWDM depende da previsão da QoT, contudo existem poucas ferramentas disponíveis para a previsão rápida e confiável. Modelos de Redes Neurais Profundas (*Deep Neural Network* – DNN) são capazes de enxergar relações complexas entre variáveis que são muito difíceis ou até impossíveis para um ser humano identificar, além de serem mais rápidas na precisão após o modelo ser treinado. Logo, é uma ferramenta habilitadora para a estimação de efeitos não lineares em conjunto com os efeitos lineares [5]. Desse modo, é possível mitigar o subaproveitamento de recursos na rede, simultaneamente garantindo qualidade de serviço e diminuição do custo.

Este artigo propõe um modelo DNN que faz a previsão precisa da GSNR em redes ópticas DWDM. O modelo é treinado com um conjunto de dados que faz parte de um conjunto de dados abertos [6], [7]. Para validar o modelo, é feita uma comparação dos resultados com uma rede simulada através da biblioteca *Optical Route Planning Library* (GNPy) [8] e são utilizados dados de uma rede real implantada para validar a estimativa do GNPy no mesmo contexto.

O presente trabalho traz um modelo de redes neurais profundas, que possui precisão e rapidez. Ao contrário de trabalhos anteriores que validam somente com modelos simulados [5] ou dados de rede real [2], este trabalho combina dois tipos de validações externas, utilizando o GNPy para avaliar o modelo e utiliza dados de uma rede real implantada para validar os resultados obtidos na simulação. O trabalho também faz um estudo de hiperparâmetros da DNN, para escolher o que melhor se enquadra para o problema em questão. Os resultados obtidos são consistentes com trabalhos anteriores [9], [5], [10].

II. COMPLEXIDADE DA PREVISÃO DA GSNR

A tecnologia DWDM é amplamente utilizada por potencializar a eficiência espectral das fibras, dividindo a banda

em vários canais com uma largura de faixa definida. Essa largura pode ser fixa ou não, de acordo com as recomendações do Setor de Normatização das Telecomunicações da União Internacional de Telecomunicações (*ITU Telecommunication Standardization Sector – ITU-T*) [11]. A tecnologia DWDM pode ser aplicada junto à tecnologia de comutação seletiva de comprimento de onda (*Wavelength Selective Switching – WSS*), formando um sistema reconfigurável e dinâmico. Além disso, é possível fazer a proteção do canal pelo nó WSS. A tecnologia DWDM é utilizada para transmissões em longas distâncias, mas também para médias e curtas distâncias e para atendimentos de acesso, já que possui robustez maior que outras tecnologias de redes metropolitana [1].

No momento do projeto, quando se determina a viabilidade de um novo sistema ou a inserção de canais na rede óptica, ao verificar se ajustes de potência ou atenuação são possíveis durante a implantação, ou durante a operação, quando é necessário comutar de um caminho para outros em casos de falhas, é indispensável analisar as métricas de qualidade de transmissão para averiguar a possibilidade de provisionar um novo canal. Essa análise deve ser rápida, precisa e computacionalmente eficiente.

A GSNR é um dos parâmetros mais importantes da QoT, calculado levando em consideração a interferência gerada pelo ruído amplificado espontâneo (*Spontaneous Emission Noise – ASE*) e a interferência não linear (*Nonlinear interference – NLI*). A relação sinal-ruído (*Signal-to-Noise Ratio – SNR*) linear pode ser calculada a partir dos equipamentos, para isso, é necessário uma caracterização de alta qualidade dos equipamentos, principalmente dos amplificadores de fibra dopada com érbio (*Erbium-Doped Fiber Amplifier – EDFA*) e suas figuras de ruído. Para a SNR não linear, um modelo de ruído gaussiano pode ser usado para modelar a NLI. Assim, a NLI pode ser modelada como um processo aleatório gaussiano aditivo adicionado por cada trecho de fibra. Contudo, esse tipo de cálculo é computacionalmente custoso [9] e envolve operações complexas, tornando a generalização e sua aplicação em tempo real ineficiente. O uso de técnicas de aprendizado profundo (*deep learning*) é uma tendência de interesse por suas características de modelar eficientemente relações complexas e apresentarem baixo custo computação para utilização após treinadas [5].

A possibilidade de um cálculo rápido e eficiente da GSNR traz benefícios em várias etapas da gerência e da operação das redes ópticas, mas em especial na operação de redes ópticas reconfiguráveis. Essas redes utilizam da tecnologia WSS, que faz o encaminhamento de cada canal individualmente. Essas redes WSS possuem normalmente vários nós e são amplamente utilizadas para proteção de segmento em substituição das chaves ópticas. Algoritmos de redes neurais no plano de controle de redes WSS tendem a diminuir drasticamente o tempo de comutação atual e ajudam a alavancar ainda mais as redes ópticas reconfiguráveis.

III. MODELO DE REDES NEURAS PROFUNDAS PARA PREVISÃO DA GSNR

Os algoritmos DNN são flexíveis porque modelam relações não lineares complexas, apresentam alta eficiência computaci-

onal após o treinamento e podem ser treinados usando dados de várias redes com características diferentes. Os algoritmos baseados em redes neurais são úteis em diversos segmentos de comunicações óptica, na compensação de não linearidades, na detecção proativa de falhas, dando maior velocidade no monitoramento de desempenho óptico [4], dentre outros [3]. Esses fatores tornam os algoritmos DNN uma ferramenta interessante para problemas de classificação e regressão aplicados a redes ópticas.

Bergk *et al.* fornecem uma coleção de conjuntos de dados usados como fontes de dados para treinamento [6], [7]. Esses conjuntos de dados foram criados a partir de simulações baseadas em topologias de redes existentes utilizando uma ferramenta de planejamento para redes ópticas (*Planning Tool for Optical Networks – PLATON*). Os conjuntos de dados compartilham as mesmas características de fator de atenuação, *span*, amplificador EDFA com ganho igual à perda do link em cada extremidade, figura de ruído e dispersão cromática. Apenas a rede e a faixa de modulação foram alteradas. O conjunto de dados consiste em 35 parâmetros. No presente trabalho, foram utilizados 30 parâmetros, conforme a Tabela I. Os metadados de simulação e os parâmetros originalmente usados para classificação de possível ou não alocação do canal foram retirados, deixando apenas o equivalente à GSNR. A Tabela II mostra exemplos de valores numéricos de cada parâmetro e o valor numérico da respectiva classe alvo.

TABELA I
PARÂMETROS UTILIZADOS

Parâmetro	Descrição
x1	Comprimento do caminho
x2	Comprimento médio do link
x3	Comprimento mínimo do link
x4	Comprimento máximo do link
x5	Número de links
x6	Número de spans
x7	Frequência da portadora
x8	Cardinalidade do formato de modulação
x9	Taxa de transmissão da trajetória de luz
x10	Taxa de transmissão da conexão
x11	Ocupação mínima do link
x12	Ocupação máxima do link
x13	Média de ocupação do link
x14	Desvio padrão da ocupação do link
x15	Número total de canais ativos ao longo do caminho da luz
x16	Máxima taxa de erro de bits dos caminhos de luz interferindo
x17	Mínima taxa de erro de bits dos caminhos de luz interferindo
x18	Média taxa de erro de bits dos caminhos de luz interferindo
x19	Mínima cardinalidade do formato de modulação (esquerda)
x20	Máxima cardinalidade do formato de modulação (esquerda)
x21	Mínima cardinalidade do formato de modulação (direita)
x22	Máxima cardinalidade do formato de modulação (direita)
x23	Taxa mínima do caminho de luz (esquerda)
x24	Taxa máxima do caminho de luz (esquerda)
x25	Taxa mínima do trajeto de luz (direita)
x26	Taxa máxima do caminho de luz (direita)
x27	Taxa Mínima de Erro de Bit (esquerda)
x28	Taxa Máxima de Erro de Bit (esquerda)
x29	Taxa Mínima de Erro de Bit (direita)
x30	Taxa Máxima de Erro de Bit (direita)

O modelo foi construído em linguagem Python, utilizando as bibliotecas *Tensorflow* e *Keras*. A Figura 1 mostra a arquitetura básica dos modelos criados. A arquitetura dos modelos consiste em uma camada de entrada de dados, em que o número de parâmetros do conjunto de dados corresponde

TABELA II
EXEMPLO DOS VALORES NUMÉRICOS DO CONJUNTO DE DADOS.

x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	x13	x14	x15	x16	x17	x18	x19	x20	x21	x22	x23	x24	x25	x26	x27	x28	x29	x30	Camada de Saída (GSNR)
467,0	116,8	99,0	143,0	4	8	192,8	32	112	112	135	25	44	33,8	6,8	0,004	0,0000	0,0011	32	32	32	32	112	112	112	112	0,00046	0,00046	0,00047	0,00047	23,54
225,0	112,5	111,0	114,0	2	4	192,2	64	112	112	107	51	56	53,5	2,5	0,004	0,0001	0,0013	64	64	64	64	224	224	112	112	0,00039	0,00039	0,00050	0,00050	26,74
547,0	136,8	89,0	223,0	4	9	194,7	32	112	112	215	42	68	53,8	9,4	0,004	0,0000	0,0017	32	32	32	32	168	168	112	112	0,00361	0,00361	0,00365	0,00365	23,11
562,5	187,5	145,3	223,8	3	8	192,4	32	112	112	92	22	39	30,7	6,9	0,003	0,0001	0,0012	16	64	8	32	112	224	112	224	0,00102	0,00334	0,00029	0,00254	23,74
2178,7	435,7	261,3	690,4	5	29	193,1	16	224	224	303	55	66	60,6	4,7	0,004	0,0000	0,0008	4	4	4	16	112	112	112	112	0,00004	0,00004	0,00044	0,00199	17,79
463,0	115,8	99,0	143,0	4	8	193,0	64	224	224	170	31	57	42,5	11,7	0,004	0,0000	0,0013	32	64	64	64	112	224	224	336	0,00070	0,00306	0,00001	0,00317	23,55
2470,5	617,6	436,9	880,0	4	34	192,5	8	168	224	111	13	44	27,8	11,1	0,003	0,0000	0,0008	4	8	4	8	56	112	112	168	0,00003	0,00056	0,00008	0,00199	17,35
472,6	236,3	177,5	295,1	2	7	192,3	64	336	448	162	78	84	81,0	3,0	0,004	0,0000	0,0009	8	8	8	8	168	168	112	112	0,00005	0,00005	0,00072	0,00072	24,12
1300,9	433,6	147,4	653,4	3	18	193,2	2	56	280	204	53	76	68,0	10,6	0,003	0,0000	0,0004	4	4	2	2	112	112	56	56	0,00002	0,00002	0,00000	0,00000	19,86
709,0	141,8	102,0	193,0	5	11	194,3	32	224	224	319	20	85	63,8	25,9	0,004	0,0000	0,0016	32	32	32	32	168	224	224	224	0,00278	0,00300	0,00185	0,00282	22,06

ao número de neurônios. Após essa camada, estão as camadas densas. Os experimentos foram realizados considerando modelos de uma até três camadas densas ocultas, com 256, 64 e 32 neurônios. Finalmente, há uma camada de saída de dados contendo apenas um neurônio. Nos modelos testados, a camada oculta tem como função de ativação a função linear retificada unitária (*Rectified Linear Unit* – ReLU) ou a função tangente hiperbólica (Tanh). O modelo conta com o otimizador *Adam* e a métrica de perda utilizada foi o erro quadrático médio (*Mean Squared Error* – MSE) no treinamento. Contudo, as métricas de erro percentual absoluto médio (*Mean Absolute Percentual Error* – MAPE) e erro médio absoluto (*Mean Absolute Error* – MAE) foram utilizadas para validação no conjunto de dados de testes. Foi utilizado o *ModelCheckpoint* para salvar automaticamente o melhor modelo e o *ReduceLROnPlateau* para ajustar a taxa de aprendizado. Vários modelos com características diferentes foram construídos e testados, a mudança das características de hiperparâmetros foram feitas para procurar o ótimo caso. Os hiperparâmetros utilizados no modelo proposto foram identificados de maneira empírica.

A simulação para validação do modelo é realizada no GNPpy, com características de uma rede real. Os dados reais foram cedidos pela gerência da Padtec. Os equipamentos padrão da biblioteca foram calibrados com os parâmetros dos equipamentos Padtec para simular os serviços ativos dentro da rede e, assim, avaliar a precisão que o GNPpy teria com aquela topologia de rede. A construção da topologia, a adaptação dos equipamentos, provisionamento dos serviços e a comparação dos resultados foram feitos de acordo com os documentos do fabricante (*Vendor*).

Atualmente, a necessidade de quantidade de canais em redes DWDM diminuiu, enquanto a de super canais, que são canais com largura de faixa maior, aumenta. A taxa de bits por símbolo já está chegando perto do limite de Shannon, assim, para maiores taxas, é necessário um aumento da largura do canal [12]. Portanto, as características da rede simulada para criação da coleção de conjunto de dados, por exemplo a utilização de apenas a banda C e divisão de grade de 37,5 GHz é difícil de ser encontrada em redes reais. Na atualidade, a grande parte dos sistemas são de 8, 20, 40, 48 ou 80 canais. A opção de 96 canais utilizando grades de 50 GHz ainda são utilizadas, mas com 37,5 GHz é difícil de encontrar em redes comerciais, além das outras características da rede em questão. Com isso, foi necessária uma simulação para validar o modelo treinado com esses dados.

Para a validação do modelo, foram feitas simulações no GNPpy. Parâmetros foram modificados para corresponder à rede a partir da qual o conjunto de dados foi criado. Como o número e a grade dos canais, de 40 para 96 e de 100 GHz para 37,5 GHz respectivamente. A faixa de frequência também foi modificada, assim como o coeficiente de atenuação da fibra e as características de ganho, potência e de figura de ruído dos amplificadores. Por fim, o resultado da simulação foi comparado ao que o modelo estimou, para aquela topologia com essas características.

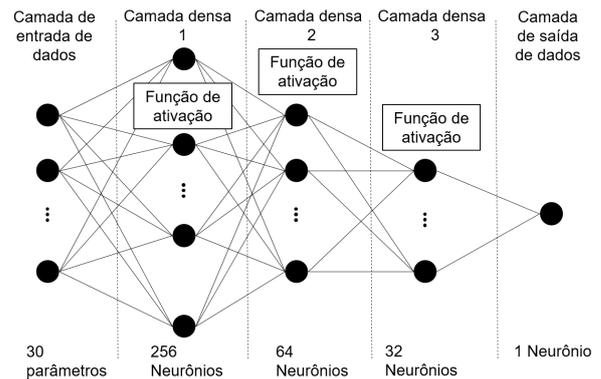


Fig. 1. Arquitetura básica do modelo. Variações do modelo são criadas com uma, duas ou três camadas ocultas. A função de ativação das camadas ocultas e da camada de saída são variadas.

IV. AVALIAÇÃO DOS RESULTADOS

O modelo de melhor desempenho é definido experimentalmente, com a realização de experimentos e a validação, tanto do modelo quanto da simulação provida pelo GNPpy, com dados de redes reais.

A. Ferramenta de Simulação

A validação é realizada usando a biblioteca GNPpy com base em dados de uma rede real implantada pela Padtec. Essa verificação consistiu na retirada de informações da rede por meio de documentação e gerência da Padtec. A topologia da rede foi montada no GNPpy e os arquivos de equipamentos e serviços foram inseridos de acordo com as propriedades da rede.

Para validação da biblioteca GNPpy, arquivos padrão de simulação do GNPpy são modificados para ter as mesmas propriedades da rede e equipamentos, isso foi feito com a

utilização do diagrama sistêmico, de dados de medições da gerência e *datasheets* dos equipamentos. Criou-se o diagrama da rede com especificações de amplificadores, *transceivers*, premissas de dispersão cromática, atenuação e dispersão dos modos de polarização (PMD). Foram usados arquivos JSON e formato XLSX para essas modificações. A biblioteca GNPY alcançou um acerto absoluto percentual de 96,89% para o trecho do canal em questão, calculando uma GSNR igual a 30,88 dB.

A partir desses resultados, uma rede foi simulada com as mesmas propriedades da rede a partir da qual o conjunto de dados de treinamento do modelo foi criado e uma topologia semelhante à rede real. Portanto, foram feitos ajustes nos parâmetros dos equipamentos e fibra óptica para refletir as características da rede a partir da qual o conjunto de dados foi gerado. Os resultados obtidos foram salvos em um arquivo CSV para validação em um modelo de redes neurais profundas. No entanto, o GNPY não fornece medições de Taxa de Erro de Bit (*Bit Error Rate* – BER). Então, foi necessário desenvolver um algoritmo para calcular a BER para cada canal com base na GSNR e cardinalidade de modulação. Os dados passaram por um pré-processamento e foram adicionados ao arquivo de validação do modelo. Para validar o modelo, foi considerado o último canal do espectro, com uma taxa de transmissão de 100 Gbit/s, utilizando a modulação PM-16QAM, para fins de simplificação e padronização com as características da rede que originou a coleção de dados de treinamento. As diferenças entre as propriedades da rede podem ser vistas na Tabela III.

TABELA III
COMPARATIVO ENTRE OS PARÂMETROS DAS REDES

Parâmetro/Rede	Dataset	Rede Real	Unidade
Comprimento do Span	80	Variável	km
EDFA Ganho	16	Variável	dB
EDFA Figura de Ruído	5	Variável	dB
Coefficiente de Atenuação	0,2	0,3	dB/km
Coefficiente de Dispersão	17	17	ps/nm/km
Faixa espectral por canal	37,5	100	GHz

B. Construção do Modelo de Redes Neurais Artificiais

Os modelos foram construídos usando o Tensorflow versão 2.10.0. Foi utilizado um método de regressão, no qual variou-se o número de camadas densas, a função de ativação e o número de neurônios para se obter uma menor perda de validação e maior precisão em comparação com as simulações realizadas com a biblioteca GNPY. Conforme mostra a Tabela IV, a função de ativação da tangente hiperbólica apresentou um menor erro absoluto percentual nas validações realizadas na rede simulada no GNPY. Na Tabela IV também é possível verificar as características de cada modelo criado e seus respectivos desempenhos na validação com as simulações do GNPY.

Foram realizados testes com o conjunto de dados cedidos por Bergk *et al.*[6], [7]. A concatenação dos quatro conjuntos de dados produziu melhores resultados em termos de erro, erro de validação e previsão da GSNR da rede simulada. A diferença entre os conjuntos de dados está na modulação e na rede que foi baseada, mantendo as mesmas características

TABELA IV
MODELOS CRIADOS E RESULTADOS

Modelo	Número de Camadas Densas	Nº de Neurônios	Activation function	OSNR previsto (dB)	Erro Percentual Médio Absoluto
64-relu	1	64	relu	32,54	5,10%
64-tanh	1	64	tanh	29,86	3,31%
256-relu	1	256	relu	32,99	6,40%
256-tanh	1	256	tanh	31,67	2,49%
256+64-relu	2	256 - 64	relu	33,17	6,90%
256+64-tanh	2	256 - 64	tanh	31,25	1,18%
256+64-tanh+relu	2	256 - 64	tanh - relu	32,62	5,33%
256+64+32-tanh	3	256 - 64 - 32	tanh	31,05	0,54%

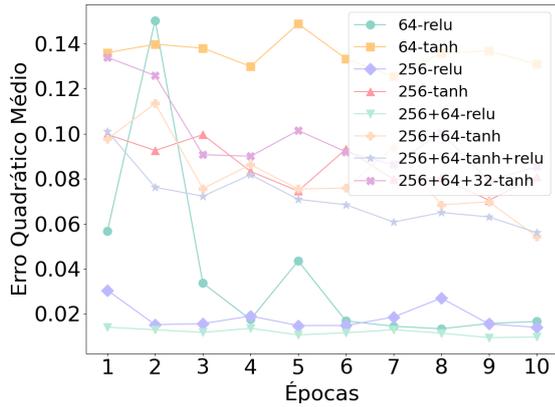
paramétricas. Assim, a concatenação trouxe uma vantagem ao treinar o modelo. Os parâmetros de metadados relacionados à simulação foram removidos.

Os arquivos do conjunto de dados foram divididos em 20% para teste e 80% para treinamento, incluindo um arquivo criado pela concatenação de quatro arquivos. Esses conjuntos de dados foram pré-processados, normalizados e passados para a fase de treinamento. Durante a fase de treinamento, oito modelos foram criados, variando suas características. Recursos como salvar o melhor modelo em treinado e o TensorBoard foram utilizados. Isso demonstrou que a função tangente hiperbólica fornece a melhor estimativa para a GSNR simulado no GNPY, mesmo com maiores erros de validação no treinamento.

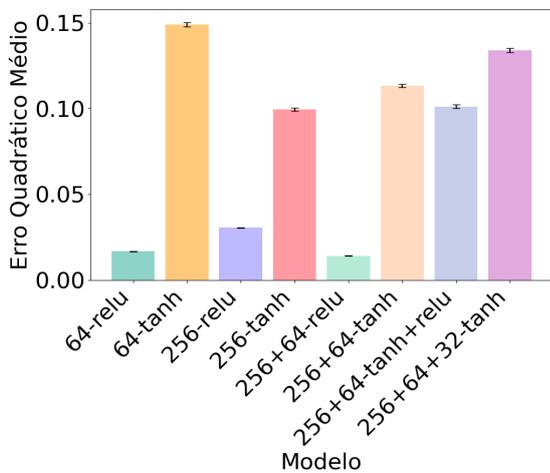
Na Figura 2(a) é possível verificar a variação do erro de validação dos modelos para cada época. A Figura 2(b) mostra um compilado do erro quadrático médio para cada modelo. Todas as métricas foram retiradas da validação dos modelos com o conjunto de dados de teste. Em todos os casos, verifica-se que os modelos que possuem a função de ativação ReLU têm um erro menor de validação do que os que possuem a função de ativação tangente hiperbólica. Contudo, quando é feita a validação com os dados da simulação do GNPY, é possível verificar que o modelo “256+64+32-tanh”, com mais camadas densas e função de ativação tangente hiperbólica é a que possui o menor erro percentual absoluto, conforme a Tabela IV. A função tangente hiperbólica é uma função não linear que trabalha com números positivos e negativos, já a função ReLU zera todos os valores negativos. Essas propriedades são úteis para aprender relacionamentos complexos entre dados quem compõe a GSNR, visto que número negativos de potência óptica em dBm são comuns.

V. TRABALHOS RELACIONADOS

O uso de redes neurais para a previsão do QoT ganhou muita relevância nos últimos anos. Vários grupos de trabalho visam desenvolver técnicas precisas, flexíveis e escaláveis para previsão de QoT, principalmente em redes ópticas reconfiguráveis. Amirabadi *et al.* propõem um estimador de QoT utilizando DNN [9]. Foram utilizados dados sintéticos, gerados por simulações baseadas em um modelo de ruído Gaussiano aprimorado (*enhanced Gaussian noise* – EGN). Os resultados obtidos foram compatíveis com os resultados obtidos neste trabalho, com um erro absoluto de até 0,3 dB. Zhang *et al.* propõem um estimador de QoT baseado em redes neurais, em que sua aplicação ocorre na previsão e avaliação do estado da rede em tempo real, com uma resposta precisa, rápida e



(a) Evolução do Erro Quadrático Médio de acordo com o número de épocas de treinamento para cada modelo.



(b) Compilado do Erro Quadrático Médio para cada modelo utilizando o conjunto de dados de teste.

Fig. 2. Métricas utilizadas para avaliação dos modelos utilizando os conjuntos de dados de teste. (a) A diferença da evolução a cada época dos modelos de diferentes características. (b) Compilado do Erro Quadrático do Erro Médio para cada modelo final, com finalidade de comparação.

dinâmica para comutação de canais em casos de rompimento de fibras [5]. Os autores demonstram que o modelo DNN foi capaz de atingir uma precisão alta com um erro absoluto menor que 0,2 dB. Tal resultado também é compatível com valores obtidos neste trabalho.

Morais e Pedro avaliam a eficácia de diversos modelos de aprendizagem de máquina e os modelos são comparados entre si [10]. Os modelos são treinados com conjuntos de dados a partir de simulações de redes reais. O modelo de redes neurais artificiais foi a que apresentou a melhor generalização, com uma precisão de aproximadamente 99%, que está de acordo com o acerto absoluto percentual de 99,46% que é o melhor modelo obtido neste trabalho. Por fim, Ferrari *et al.* fazem a validação da biblioteca GNPpy, em comparação com dados advindos de uma rede real [2]. Os autores mostram que para 90% dos casos, o GNPpy consegue uma acurácia de até 1 dB de diferença, que está de acordo com o que foi obtido na validação deste trabalho.

VI. CONCLUSÃO

Esse artigo propôs um modelo de redes neurais profundas para a estimação precisa e rápida da GSNR. Vários modelos foram construídos e testados, alterando os hiperparâmetros DNN para encontrar a configuração ótima para o problema. Uma coleção de conjuntos de dados sintéticos para o treinamento foi usada e o modelo foi validado por uma rede simulada utilizando a biblioteca GNPpy. Além disso, a precisão do GNPpy foi validada utilizando dados de uma rede real implantada na Padtec. Foi observado que o modelo DNN proposto possui um erro percentual absoluto de 0,54%, com erros absolutos condizentes com os encontrados em trabalhos anteriores. Trabalhos futuros focam o desenvolvimento de um plano de controle usando previsões de QoT para redes ópticas reconfiguráveis.

AGRADECIMENTOS

Os autores agradecem à Padtec S/A por conta da disponibilização dos dados e a Bergk *et al.* por cederem a coleção de conjuntos de dados “*QoT Dataset Collection*” para treinamento dos modelos.

REFERÊNCIAS

- [1] B. Skubic, G. Bottari, P. Öhlén, and F. Cavaliere, “The role of dwdm for 5g transport,” in *2014 The European Conference on Optical Communication (ECOC)*, 2014, pp. 1–3.
- [2] A. Ferrari, M. Filer, K. Balasubramanian, Y. Yin, E. Le Rouzic, J. Kundrat, G. Grammel, G. Galimberti, and V. Curri, “Experimental validation of an open source quality of transmission estimator for open optical networks,” in *2020 Optical Fiber Communications Conference and Exhibition (OFC)*, 2020, pp. 1–3.
- [3] F. N. Khan, Q. Fan, C. Lu, and A. P. T. Lau, “An optical communication’s perspective on machine learning and its applications,” *Journal of Lightwave Technology*, vol. 37, no. 2, pp. 493–516, 2019.
- [4] X. Wu, J. A. Jargon, R. A. Skoog, L. Paraschis, and A. E. Willner, “Applications of artificial neural networks in optical performance monitoring,” *Journal of Lightwave Technology*, vol. 27, no. 16, pp. 3580–3589, 2009.
- [5] Y. Zhang, Y. Song, Y. Shi, J. Li, C. Zhang, Y. Tang, M. Zhang, and D. Wang, “Deep neural network-enabled fast and large-scale qot estimation for dynamic c+l-band mesh networks,” in *2023 Optical Fiber Communications Conference and Exhibition (OFC)*, 2023, pp. 1–3.
- [6] G. Bergk, B. Shariati, P. Safari, and J. K. Fischer, “MI-assisted QoT estimation: a dataset collection and data visualization for dataset quality evaluation,” *Journal of Optical Communications and Networking*, vol. 14, no. 3, pp. 43–55, Mar. 2022.
- [7] G. Bergk, B. Shariati, P. Safari, and J. K. Fischer, “*QoT Dataset Collection*”. URL: <https://www.hhi.fraunhofer.de/networkdata>.
- [8] GNPpy, “Optical route planning library,” URL: <https://github.com/Telecominfraproject/oopt-gnpy>.
- [9] M. A. Amirabadi, M. H. Kahaei, S. A. Nezamalhoseini, F. Arpanaei, and A. Carena, “Deep neural network-based qot estimation for smf and fmf links,” *Journal of Lightwave Technology*, vol. 41, no. 6, pp. 1684–1695, 2023.
- [10] R. M. Moraes and J. Pedro, “Evaluating machine learning models for qot estimation,” in *2018 20th International Conference on Transparent Optical Networks (ICTON)*, 2018, pp. 1–4.
- [11] ITU-T, “ITU-T G.694.1-2: Spectral grids for WDM applications: Flex-Grid,” ITU-T Recommendation, 2016, Geneva, Switzerland: ITU-T Publishing.
- [12] J. Rahn, S. Kumar, M. Mitchell, H. Sun, K.-T. Wu, G. Goldfarb, M. Kato, D. Krause, R. Nagarajan, F. Kish, and D. Welch, “Superchannels: Dwdm transmission beyond 100 gb/s,” in *IEEE Photonics Conference 2012*, 2012, pp. 854–855.