

Machine Learning como Ferramenta para Otimização de Redes Ópticas WDM: Análise de Perdas e Predição de Qualidade

Y. Martínez-Camejo, Ana V. P. Fernandes, Vanessa B. Deniz, Rogean C. Silva, J. S. de Andrade e G. F. Guimarães

Resumo— Neste trabalho investiga-se a aplicação de algoritmos de *Machine Learning* (ML) para otimizar o desempenho de redes ópticas WDM (*Wavelength Division Multiplexing*). Através de simulações computacionais no *software OptiSystem* foi gerada uma base de dados variando parâmetros de entrada relacionados ao gerenciamento de perdas, como potência do WDM e potência de bombeamento EDFA (*Erbium Doped Fiber Amplifiers*). Os modelos de ML foram treinados utilizando algoritmos de regressão como *Boosted Decision Tree Regression* (BDTR), *Decision Forest Regression* (DFR) e *Histogram Gradient Boosting Regression* (HGBR). Os resultados obtidos provaram que o ML é uma ferramenta poderosa para prever QoT em redes ópticas.

Palavras-Chave— Machine Learning, Redes Ópticas WDM, Algoritmos de regressão.

Abstract— This work investigates the application of Machine Learning (ML) algorithms to optimize the performance of WDM (*Wavelength Division Multiplexing*) optical networks. Through computer simulations in the *OptiSystem* software, a database was generated varying input parameters related to loss management, such as WDM power and EDFA (*Erbium Doped Fiber Amplifiers*) pumping power. The ML models were trained using regression algorithms such as *Boosted Decision Tree Regression* (BDTR), *Decision Forest Regression* (DFR) and *Histogram Gradient Boosting Regression* (HGBR). The results obtained proved that ML is a powerful tool for predicting QoT in optical networks.

Keywords— Machine Learning, WDM Optical Networks, Regression Algorithms.

I. INTRODUÇÃO

O tráfego de dados em redes de comunicação tem experimentado um crescimento exponencial nas últimas décadas, impulsionado pela crescente demanda por serviços de internet de alta velocidade, *streaming* de vídeo em alta definição, Internet das Coisas (IoT) e a chegada da tecnologia 5G. Para suportar essa crescente necessidade por capacidade de transmissão, as redes ópticas, baseadas na tecnologia WDM (*Wavelength Division Multiplexing*), tornaram-se a espinha dorsal da infraestrutura de comunicação global. No entanto, o gerenciamento eficiente dessas redes, com o objetivo de garantir a qualidade da transmissão (QoT) e otimizar o uso dos recursos, apresenta desafios significativos.

Tradicionalmente, a análise de desempenho e a predição de QoT em redes ópticas são realizadas por meio de modelos

analíticos complexos que levam em consideração as diversas deficiências físicas do sistema, como atenuação, dispersão e efeitos não lineares [1]. Embora precisos, esses modelos são computacionalmente intensivos, o que os torna inadequados para aplicações em tempo real, como o provisionamento dinâmico de conexões. Uma alternativa é a utilização de fórmulas simplificadas com altas margens de segurança, que garantem a QoT, mas levam à subutilização dos recursos da rede, elevando os custos operacionais.

Nesse contexto, o *Machine Learning* (ML), um ramo da Inteligência Artificial (IA), surge como uma ferramenta promissora para otimizar o desempenho de redes ópticas. Algoritmos de ML podem ser treinados com dados de redes reais para aprender os padrões de comportamento do sistema e, a partir disso, realizar predições precisas de QoT, otimizar o uso dos recursos e auxiliar na tomada de decisões em tempo real. Diversos trabalhos na literatura já demonstraram a viabilidade do ML na análise e otimização de redes ópticas.

Rudra et al. [2] utilizaram modelos de regressão multivariável e redes neurais para prever o Máximo Fator Qualidade (Max_Q_Factor) e a mínima taxa de erro de bit (Min_BER) em sistemas DWDM (*Dense Wavelength Division Multiplexing*), com base em dados simulados no *software OptiSystem*. Manso et al. [3] propuseram uma arquitetura nativa em nuvem baseada em ML para predição de QoT em uma rede WDM sobre SDM (*Space Division Multiplexing*), validando experimentalmente a escalabilidade e a precisão dos modelos. D'Amico et al. [4] utilizaram um algoritmo de ML treinado com dados experimentais para prever a relação sinal-ruído (SNR) em um sistema de linha óptica ponto a ponto com múltiplos amplificadores EDFA, demonstrando a capacidade do ML em lidar com cargas espectrais variadas e flutuações nas respostas dos amplificadores.

Este trabalho se propõe a investigar a aplicação de algoritmos de ML para a predição de QoT em redes ópticas WDM, com foco na análise de perdas e na otimização do uso dos recursos da rede. A pesquisa se baseia em dados simulados no *software OptiSystem*, utilizando como referência redes ópticas reais existentes no Ceará. Diferentes algoritmos de regressão serão avaliados, comparando sua precisão na predição de parâmetros como potência total (Total_Power), ganho total (Total_Gain), máximo fator de qualidade (Max_Q_Factor) e taxa mínima de variação de erro de bit (Min_BER). Os resultados esperados incluem a identificação do algoritmo de ML mais adequado para a predição de QoT em redes ópticas WDM, a análise da influência da correlação entre os

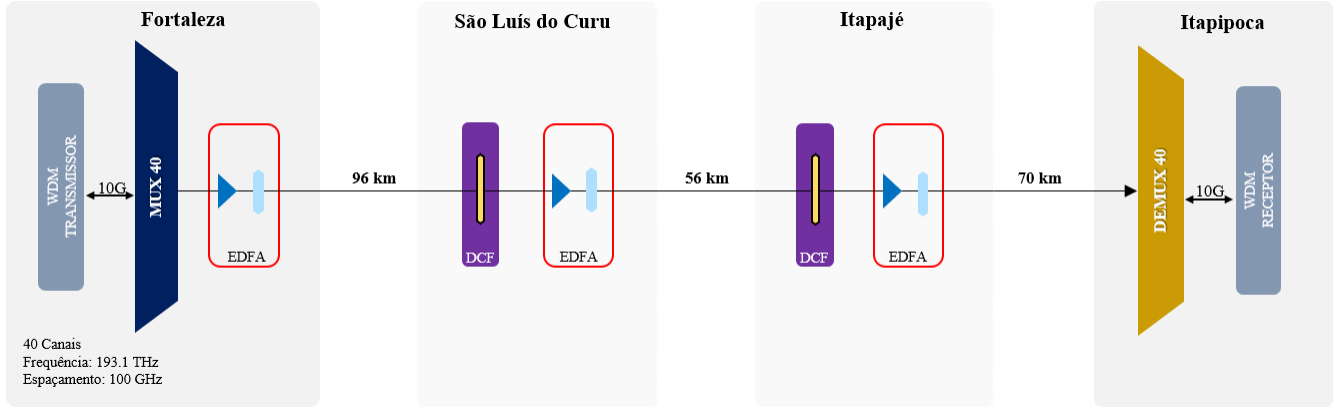


Fig. 1. Sistema DWDM e seus componentes da rede óptica simulada no *OptiSystem* utilizando como parâmetros de entrada os de uma rede real que une a cidade de Fortaleza com a de Itapipoca

parâmetros de entrada e saída na precisão das previsões, e a proposição de um *framework* para a otimização de redes ópticas baseado em ML.

A aplicação do ML em redes ópticas apresenta um grande potencial para transformar a maneira como essas redes são gerenciadas e otimizadas. A capacidade de realizar previsões precisas de QoT em tempo real, otimizar o uso dos recursos e auxiliar na tomada de decisões pode levar a uma redução significativa nos custos operacionais, além de melhorar a qualidade dos serviços oferecidos aos usuários. As perspectivas futuras incluem a integração de modelos de ML em controladores SDN (*Software Defined Networking*) para o gerenciamento autônomo de redes ópticas, a utilização de *Deep Learning* para lidar com cenários mais complexos e a aplicação de ML para a detecção e diagnóstico de falhas em tempo real.

II. METODOLOGIA

Para investigar a aplicação de *Machine Learning* na otimização de redes ópticas WDM, este estudo empregou uma abordagem de simulação computacional. Os dados para treinamento e avaliação dos modelos de ML foram gerados a partir de simulações no *software OptiSystem 7.0*, tendo como base uma rede óptica real de um provedor de internet do Ceará, como apresentado na Figura 1. A rede óptica simulada consiste em um enlace WDM ponto a ponto de 222 km, conectando Fortaleza a Itapipoca, passando pelas cidades de São Luís do Curu e Itapajé. Operando na janela de 1550 nm, o sistema utiliza fibra óptica monomodo padrão G.652 com atenuação de 0,2 dB/km, suportando uma capacidade de 10 Gbps por canal em um total de 40 canais WDM multiplexados.

A topologia da rede simulada inclui um transmissor WDM configurado com 40 canais, espaçamento de 100 GHz e modulação NRZ, com a frequência do canal analisado fixada em 193,1 THz (canal 31 da banda C). Três amplificadores EDFA são utilizados ao longo do enlace para compensar as perdas: um *booster* na saída do transmissor e dois amplificadores de linha. Adicionalmente, fibras DCF são inseridas após cada amplificador para mitigar a dispersão cromática. Multiplexadores/demultiplexadores WDM combinam e separam os canais, enquanto um receptor óptico recebe o sinal do canal 31 após a demultiplexação. O Analisador BER, componente do

OptiSystem, fornece as métricas de QoT: potência total, ganho total, mínimo BER e máximo Fator Q.

A base de dados para o treinamento dos modelos de *Machine Learning* foi gerada a partir de 366 simulações no *OptiSystem*, variando a potência do transmissor WDM (2 dBm a 12 dBm) e a potência de bombeamento dos amplificadores EDFA (20 dBm a 35 dBm para cada amplificador). Para cada simulação, foram coletados os parâmetros de saída mencionados. Os dados coletados foram utilizados para treinar e avaliar três algoritmos de regressão: *Boosted Decision Tree Regression* (BDTR) [5] [8][9] [10] [13][14], *Decision Forest Regression* (DFR) [6][7] e *Histogram Gradient Boosting Regression* (HGBR) [11][12]. A implementação dos modelos de *Machine Learning* foi realizada em *Python 3.9*, utilizando as bibliotecas *scikit-learn* e *pandas*.

A base de dados foi dividida em 80% para treinamento e 20% para avaliação, com a escolha dos parâmetros de cada algoritmo otimizada por validação cruzada. O desempenho dos modelos foi avaliado com base no coeficiente de determinação (R^2) e nas métricas de erro MAE e MSE. Uma análise de correlação, utilizando o coeficiente de correlações de Pearson, Spearman e Kendall foi realizada para entender a relação entre os parâmetros de entrada e saída, visualizada por meio de mapas de calor. Finalmente, os valores preditos pelos modelos de *Machine Learning* foram comparados com os valores simulados no *OptiSystem*, a fim de validar a precisão das previsões, utilizando gráficos para visualizar as diferenças entre os valores para diferentes configurações dos parâmetros de entrada.

III. RESULTADOS

A Figura 2 apresenta os *Heatmap* (mapas de calor) para as correlações de Pearson (r), Spearman (ρ) e Kendall (τ) para as variáveis de entrada (Power_WDM, EDFA1, EDFA2 e EDFA3) e os alvos (Total_Gain, Total_Power, Min_BER e Max_Q_Factor).

A correlação de Pearson é dada pela Equação 1, onde x_i, y_i são os pontos amostrais individuais indexados com i e $\bar{x} =$

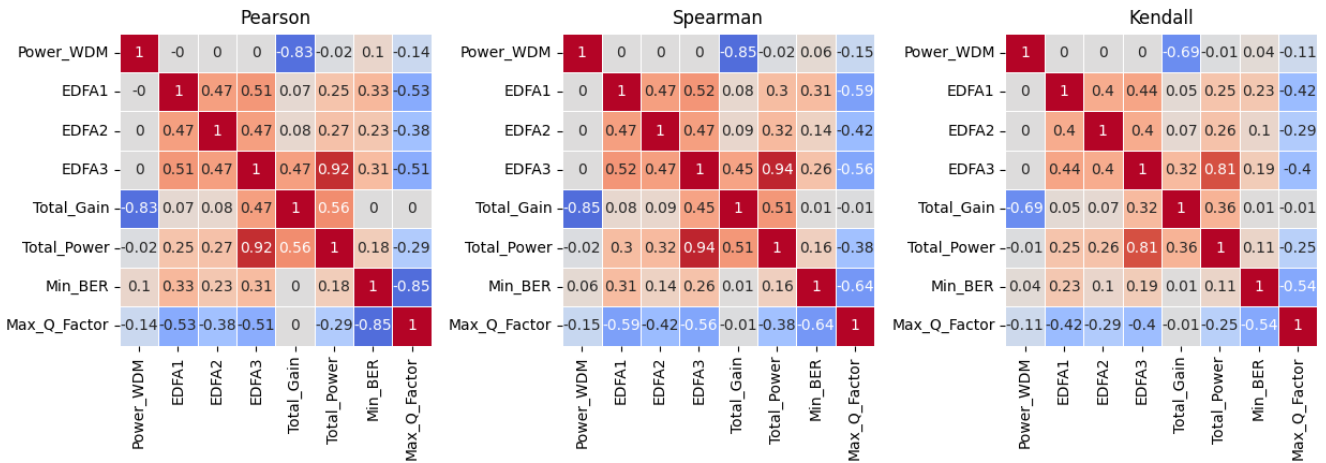


Fig. 2. Heatmap usando as matrizes de correlação de Pearson, Spearman e Kendall correlacionando as variáveis alvos com as de entrada.

$\frac{1}{n} \sum_{i=1}^n x_i$ (a média da amostra); analogamente para \bar{y} .

$$r = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (1)$$

Por sua vez, a correlação de Spearman é dada pela Equação 2, onde $d_i = R(X_i) - R(Y_i)$ é a diferença entre os dois ubicações de cada observação na base de dados e n é o número de observações.

$$\rho = 1 - \frac{6 \sum_i d_i^2}{n(n^2 - 1)} \quad (2)$$

Além disso, a correlação de Kendall é dada pela Equação 3, onde $S = cp - dp$ é a diferença entre os pares concordantes (cp) e os pares discordantes (dp) [15].

$$\tau = \frac{2S}{n(n-1)} \quad (3)$$

Na Figura 2 podemos observar que em todos os casos a variável de entrada Power_WDM e o alvo Total_Power apresentam uma correlação monotonicamente decrescente forte, assim como, o alvo Max_Q_Factor apresenta uma correlação monotonicamente decrescente moderada em relação às potências de bombeio dos EDFA1, EDFA2 e EDFA3. Por outro lado o Min_BER e o Total_Gain apresentam correlações fracas e muito fracas, respectivamente, em relação as variáveis de entrada Power_WDM, EDFA1, EDFA2 e EDFA3. Esta fraca correlação indica que existe uma complexidade em achar um padrão ou lei que relacione as variáveis de entradas com esses alvos, sendo mais forte no caso do alvo Total_Gain.

Seguidamente foi realizar a busca dos melhores hiperparâmetros e validação cruzada para os modelos de regressão estudados usando uma proporção da base de treinamento/ teste do 80:20 para otimizar o aprendizado e obter melhores resultados em cada treinamento. Os melhores parâmetros encontrados para o BDTR foram: $learning_rate = 0.01$, $max_depth = 3$, $min_samples_leaf = 1$, $min_samples_split = 2$, $n_estimators = 300$, com valores do MSE iguais a 1,0789 e 1,6663 para a base de treinamento e teste, respectivamente. Além de obter pontuações RMSE de validação cruzada (1,2494; 1,4769;

1,3048; 1,3471; 1,2512) e um RMSE médio de validação cruzada igual a 1,3259.

Para o algoritmo RFR seguindo a mesma configuração que anterior da porcentagem treinamento/teste, os melhores parâmetros encontrados foram: $max_profundidade = Nenhum$, $min_samples_leaf = 2$, $min_samples_split = 2$, $n_estimators = 600$, com pontuações RMSE de validação cruzada (1,1647; 1,2555; 1,2901; 1,3412; 1,2588), um RMSE médio de validação cruzada igual a 1,2621 e um MSE do teste igual 1,6829.

Por outro lado, para o algoritmo HGBR seguido as mesmas configurações da porcentagem treinamento/teste os melhores parâmetros encontrados foram: $l2_regularization = 0,1$, $learning_rate = 0,01$, $max_profundidade = 4$, $max_iter = 300$, $min_samples_leaf = 1$, pontuações RMSE de validação cruzada (1,2006; 1,4021; 1,2919; 1,4079; 1,3048), RMSE médio de validação cruzada igual a 1,3215 e MSE do teste igual 1,6609. Com os melhores parâmetros encontrados investigou-se a partir de que porcentagem da relação treinamento/teste os modelos tinham melhor desempenho, o qual pode ser inferido da Figura 3.

Mediante a Figura 3, podemos avaliar o desempenho de três modelos de regressão utilizados (BDTR, RFR, HGBR) na predição dos quatro parâmetros alvos de interesse (Max_Q_Factor, Min_BER, Total_Gain e Total_Power). O desempenho dos modelos foi avaliado utilizando diferentes tamanhos de base de treinamento, variando de 10% a 90% do tamanho da base de dados, utilizando como métricas de avaliação R^2 , MAE (*Mean Absolute Error*) e MSE (*Mean Squared Error*).

Na Figura 3 (a,b, c e d), podemos observar a partir do coeficiente de determinação R^2 , que o algoritmo BDTR demonstrou um desempenho superior em relação aos outros modelos na predição de Max_Q_Factor, atingindo um valor de R^2 de aproximadamente 0,95 com 10% da base de treinamento e mantendo um desempenho consistente até 90% dos dados. Para a variável alvo Min_BER, o BDTR também apresentou o melhor R^2 , com um valor acima de 0,90 para todos os tamanhos de base de treinamento, enquanto HGBR e RFR apresentaram valores de R^2 inferiores a 0,85. Para

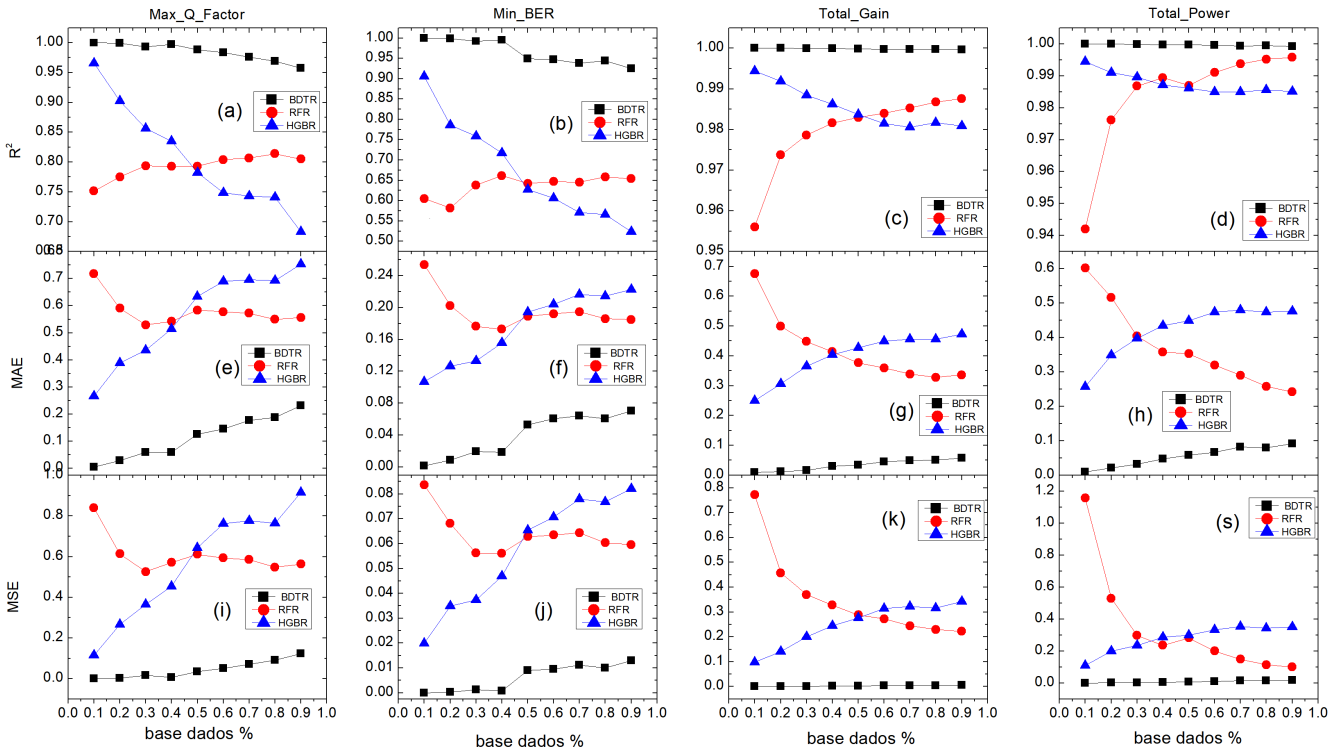


Fig. 3. Resultado do treinamento da base de dados utilizando os modelos HGBE, RFR e BDTR, nas figuras (a,b, c e d) observa-se os valores do coeficiente de determinação R^2 , nas (e, d, f e g) o MAE (Mean Absoluto Error) e nas (i, j, k e s) o MSE (Mean Squared Error), para cada modelo variando a base de treinamento de 10 até um 90 %

Total_Gain, o BDTR alcançou um R^2 de 0,99 com 10% dos dados, enquanto RFR e HGBR ficaram próximos de 0,98. O BDTR também obteve o melhor desempenho na predição de Total_Power, atingindo um R^2 superior a 0,98, enquanto os outros modelos ficaram abaixo de 0,97.

Por outro lado, na Figura 3 (e, d, f e g) mostra que para o MAE, o algoritmo BDTR apresentou os menores valores de MAE para todas as variáveis em todos os tamanhos de base de treinamento. Na predição de Max_Q_Factor, o MAE do BDTR variou de 0,02 a 0,2, enquanto os outros modelos apresentaram valores superiores a 0,10. Para Min_BER, o MAE do BDTR ficou abaixo de 0,07, enquanto os outros modelos atingiram valores acima de 0,10. Para Total_Gain, o MAE do BDTR ficou abaixo de 0,05, enquanto os outros modelos ficaram acima de 0,10. Na predição de Total_Power, o BDTR apresentou um MAE inferior a 0,04, enquanto os outros modelos ficaram acima de 0,10.

Além disso, na Figura 3 (i, j, k e s) observa-se que para o MSE o algoritmo BDTR também apresentou o menor MSE para todas as variáveis em todos os tamanhos de base de treinamento. Na predição de Max_Q_Factor, o MSE do BDTR variou de $0,3e-4$ a 0,1, enquanto os outros modelos apresentaram valores superiores a 0,1. Para Min_BER, o MSE do BDTR ficou abaixo de 0,01, enquanto os outros modelos atingiram valores acima de 0,1. Para Total_Gain, o MSE do BDTR ficou abaixo de 0,01, enquanto os outros modelos ficaram acima de 0,005. Na predição de Total_Power, o HGBR apresentou um MSE inferior a 0,001, enquanto os outros

modelos ficaram acima de 0,002.

O que nos leva a concluir que modelo BDTR se mostrou superior aos outros modelos na predição de todos os parâmetros avaliados neste estudo. O BDTR apresentou um desempenho consistente em diferentes tamanhos de base de treinamento, com valores mais altos de R^2 e menores valores de MAE e MSE. O modelo HGBR apresentou um desempenho inferior aos outros dois modelos na maioria das variáveis, especialmente em relação ao MAE e MSE. O modelo RFR apresentou um desempenho mediano, com resultados mistos em diferentes variáveis. Os resultados obtidos indicam que o HGBR é uma opção promissora para a predição dos parâmetros relacionados as perdas e qualidade do sinal de uma rede óptica WDM, proporcionando alta precisão e confiabilidade em diferentes cenários de treinamento.

IV. CONCLUSÕES

Pudo-se concluir que os alvos que possuem uma maior correlação com os parâmetros de entrada são o Min_BER, Total_Power e o Max_Q_Factor, estes tiveram melhores resultados em comparação aos que possuíam uma menor correlação, que é o Total_Gain. Os resultados apresentados eram esperados devido ao fato de que o objetivo inicial da pesquisa visava o gerenciamento de perdas.

Também foi observado que, para a base de dados simulada, o algoritmo BDTR apresentou melhor desempenho na análise de todas as variáveis alvos de interesse. Desta forma, constata-se que a aplicação do ML é um campo promissor para o

estudo de melhorias de redes ópticas, visto que o uso de algoritmos nos fornecem soluções viáveis sem a necessidade de estudo de todos os cenários possíveis que irão direcionar o planejamento de sistemas de comunicações ópticas, com o objetivo de minimizar as altas margens inseridas nos projetos reais, que elevam os custos e subutilizam os recursos da rede.

Sugere-se que para trabalhos futuros a base de dados seja ampliada, e que além da análise dos parâmetros de gerenciamento de dispersão que são mais correlacionados com a análise de QoT se inserem novos parâmetros na simulação da base de dados a fim de obter mais informações do sistema. Assim como se sugere a inserção de outros métodos de ML com mais robustez.

AGRADECIMENTOS

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (88887.750790/2022-00, 88887.707631/2022-00); Conselho Nacional de Desenvolvimento Científico e Tecnológico - Projeto Universal (409071/2021-8).

REFERÊNCIAS

- [1] AGRAWAL, G. P. *Fiber-optic Communication Systems*. 4. ed. Hoboken: John Wiley & Sons, 2010.
- [2] RUDRA, R. et al. *Applying Regression Models to Calculate the Qfactor of Multiplexed Video Signal based on Optisystem*. In: SAI INTELLIGENT SYSTEMS CONFERENCE (IntelliSys), 2015. Anais... London: SAI, 2015.
- [3] MANSO, C. et al. *Scalability analysis of machine learning QoT estimators for a cloud-native SDN controller on a WDM over SDM network*. *Journal of Optical Communications and Networking*, v. 14, n. 4, p. 257-266, 2022.
- [4] D'AMICO, A. et al. *Enhancing Lightpath QoT Computation With Machine Learning in Partially Disaggregated Optical Networks*. *IEEE Open Journal of the Communications Society*, v. 2, p. 564-574, 2021.
- [5] BREIMAN, L., *Classification and Regression Trees* (Routledge, 2017).
- [6] BREIMAN, L., *Random forests*, *Mach. Learn.* 45, 5–32 (2001).
- [7] GEURTS, P., ERNST, D., and WEHENKEL, L., *Extremely randomized trees*, *Mach. Learn.* 63, 3–42 (2006).
- [8] FRIEDMAN, J. H., *Greedy function approximation: a gradient boosting machine*, *Ann. Statist.* 29, 1189–1232 (2001).
- [9] HASTIE, T. , TIBSHIRANI, R. , FRIEDMAN, J. H. , et al., *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (Springer, 2009), Vol. 2.
- [10] FRIEDMAN, J. H. , *Stochastic gradient boosting*, *Comput. Statist. Data Anal.* 38, 367–378 (2002).
- [11] MAYER, M. , BOURASSA, S. C. , HOESLI, M. , et al., *Machine learning applications to land and structure valuation*, *J. Risk Finan. Manage.* 15, 193 (2022).
- [12] FISHER, W. D., *On grouping for maximum homogeneity*, *J. Am. Stat. Assoc.* 53, 789–798 (1958).
- [13] DRUCKER, H., *Improving regressors using boosting techniques*, in 14th International Conference on Machine Learning (ICML) (Citeseer, 1997), Vol. 97, pp. 107–115.
- [14] HASTIE, T., ROSSET, S. , ZHU, J. , et al., *Multi-class adaboost*, *Stat. Interface* 2, 349–360 (2009).
- [15] KENDALL, M. G., *Rank Correlation Methods*, 4th ed. (1970).