

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE-UFCG
CAMPUS DE CAMPINA GRANDE
ENGENHARIA ELÉTRICA**

VITOR ARAUJO MATOS

**RECUPERAÇÃO DE FASE DE SINAIS ÓPTICOS BASEADA EM *MACHINE
LEARNING***

**CAMPINA GRANDE
2021**

Vitor Araujo Matos

Recuperação de Fase de Sinais Ópticos Baseada em *Machine Learning*

Trabalho de conclusão de curso apresentada como requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica da Universidade Federal de Campina Grande - UFCG, Campus de Campina Grande.

Orientador: Prof. Dr. Edson Porto da Silva

Campina Grande
2021

Vitor Araujo Matos

Recuperação de Fase de Sinais Ópticos Baseada em *Machine Learning*

Trabalho de conclusão de curso apresentada como requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica da Universidade Federal de Campina Grande - UFCG, Campus de Campina Grande.

Data de Aprovação: 21/10/2021

Banca Examinadora

Prof. Dr. Edson Porto da Silva
Universidade Federal de Campina Grande
Campus Campina Grande
Orientador

Prof. Dr. Adolfo Fernandes Herbster
Universidade Federal de Campina Grande
Campus Campina Grande
Examinador

Dedico este trabalho à minha família, que sempre me deu apoio na minha jornada.

AGRADECIMENTOS

Agradeço primeiramente ao meu pai, que me deu todo o apoio necessário para que eu pudesse me focar inteiramente nos estudos para conseguir realizar esse sonho, que também é dele. Agradeço à minha mãe, que sempre me deu todo o apoio emocional para passar por todas as dificuldades encontradas nessa jornada acadêmica.

Agradeço aos professores da UFCG com que tive contato e que me proporcionaram uma graduação sólida e profissionalizante. Agradecimento em especial aos professores Adolfo Herbster e Edson Porto, por terem me dado a oportunidade de participar de estudos e projetos que me proporcionaram excelente crescimento profissional e pessoal.

Agradeço também aos meus colegas e amigos, por estarem comigo nos momentos bons e ruins sempre me dando apoio.

Existirão mil motivos para você desistir e apenas um para continuar: Sua força de vontade.

Mestre Diego Pinho

RESUMO

Sistemas de comunicações ópticas coerentes se tornaram o estado da arte para a criação de novas arquiteturas de sistemas de comunicações ópticas. No entanto, novos algoritmos com maior viabilidade econômica e computacional vêm sendo pesquisados para serem implementados, principalmente, em sistemas de curta e média distâncias. O avanço e a popularização de novas linguagens de programação, como a linguagem Python, e também dos *frameworks* especializados para a criação de algoritmos de aprendizado de máquina e redes neurais artificiais apresentam um excelente ambiente de desenvolvimento. Considerando a necessidade de técnicas de recepção e detecção de sinais, este trabalho tem como objetivo geral o estudo e implementação de técnica de processamento digital de sinais utilizando algoritmos de aprendizado de máquina, baseados em redes neurais artificiais, para detecção de fase de sinais ópticos por detecção direta utilizando treinamento supervisionado. As redes neurais implementadas apresentaram bons resultados frente ao algoritmo de Kramers-Kronig presente na literatura.

Palavras-chave: Detecção coerente. Detecção direta. Rede neural artificial. Algoritmo de Kramers-Kronig. Comunicações ópticas.

ABSTRACT

Coherent optical communications systems have become the state of the art for creating new optical communications system architectures. However, new algorithms with greater economic and computational feasibility have been researched to be implemented, mainly, in short and medium distance systems. The advancement and popularization of new programming languages, such as the Python language, and also of specialized *frameworks* for the creation of machine learning algorithms and artificial neural networks present an excellent development environment. Considering the need for signal reception and detection techniques, this work has as general objective the study and implementation of a digital signal processing technique using machine learning algorithms, based on artificial neural networks, for optical signal phase detection by direct detection using supervised learning. The implemented neural networks showed good results against the Kramers-Kronig algorithm present in the literature.

Keywords: Coherent detection. Direct detection. Artificial neural network. Kramers-Kronig algorithm. Optical communications.

LISTA DE FIGURAS

Figura 1 – Diagrama de um sistema comum de comunicações coerentes. Fonte autoral.	15
Figura 2 – Geração de sinais de fase mínima. Fonte autoral.	17
Figura 3 – Diagrama ilustrativo de um perceptron. Fonte autoral	18
Figura 4 – Gráfico das funções de ativação utilizadas no trabalho. Fonte autoral.	19
Figura 5 – Diagrama ilustrativo de uma RNA multicamada.	19
Figura 6 – Diagrama de blocos da rede neural com 256 entrada feito pelo <i>framework</i> keras.	22
Figura 7 – Procedimento utilizado na simulação.	24
Figura 8 – Análise comparativa entre as BER teórica para o canal AWGN e do canal simulado para transmissão de sinais QAM.	24
Figura 9 – Constelação do sinal QAM de fase mínima, com CSPR igual a 17 dB, utilizado para o treinamento das redes neurais.	25
Figura 10 – Processo de recuperação de fase feito pela RNA.	25
Figura 11 – Curvas da BER vs SNR para sinais 64 QAM recebidos à 2 SpS com CSPR igual a 17 dB. Redes neurais treinadas com diferentes valores de entradas.	27
Figura 12 – Curvas da BER vs SNR para sinais 64 QAM recebidos à 4 SpS com CSPR igual a 17 dB. Redes neurais treinadas com diferentes valores de entradas.	28
Figura 13 – Comparação entre curvas da BER vs SNR para sinais 64 QAM recebidos à diferentes valores de sobre amostragem e 10 dB de CSPR. Rede neural treinada com 256 entradas.	29
Figura 14 – Curvas da BER vs SNR para sinal 64 QAM recebido. Rede neural treinada com 256 entradas e sinais amostrados à 4 SpS.	30
Figura 15 – Curvas da BER vs SNR para sinais 16 QAM recebidos com 17 dB de CSPR. Redes neurais treinadas com diferentes valores de entradas	31
Figura 16 – Curvas da BER vs SNR para sinal 16 QAM recebido com 10 dB de CSPR. Rede neural treinada com 256 entradas.	32
Figura 17 – Curvas da BER vs SNR para sinal 16 QAM recebido à 2 SpS. Rede neural treinada com 256 entradas.	32
Figura 18 – Curvas da BER vs SNR para sinal 16 QAM recebido à 4 SpS. Rede neural treinada com 256 entradas.	33

LISTA DE ABREVIATURAS E SIGLAS

LO	<i>Local Oscillator</i>
KK	Kramers-Kronig
RNA	Rede Neural Artificial
DD	Detecção Direta
DC	Detecção Coerente
PDS	Processamento Digital de Sinais
BER	<i>Bit Error Rate</i>
SNR	<i>Signal to Noise Ratio</i>
OSNR	<i>Optical Signal to Noise Ratio</i>
FEC	<i>Forward Error Correction</i>
QAM	<i>Quadrature-Amplitude Modulation</i>
PSK	<i>Phase Shift Keying</i>
SpS	<i>Samples per Symbol</i>
CSPR	<i>Carrier-to-signal power ratio</i>
Hz	Hertz
b	bits
B	Bytes
s	segundo
MSE	<i>Mean Squared Error</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	TRANSMISSOR COERENTE DE KK	16
2.1.1	SINAL DE FASE MÍNIMA	16
2.2	REDES NEURAIS	17
2.2.1	Treinamento supervisionado	18
3	ESCOPO DO PROBLEMA E SOLUÇÃO PROPOSTA	21
3.1	ALGORITMO PROPOSTO	21
4	MATERIAL E MÉTODOS	23
4.1	SIMULAÇÃO DA TRANSMISSÃO QAM	23
4.2	TREINAMENTO DA REDE NEURAL	24
5	RESULTADOS	26
5.1	DETECÇÃO DE SINAIS 64-QAM	26
5.1.1	Comparação entre sinais com diferentes sobre amostragens	28
5.1.2	Comparação entre sinais com diferentes CSPRs	29
5.2	DETECÇÃO DE SINAIS 16-QAM	29
5.2.1	Reutilização das redes neurais	29
5.2.2	Comparação entre sinais com diferentes sobre amostragens	30
5.2.3	Comparação entre sinais com diferentes CSPRs	32
6	CONCLUSÃO	34
	REFERÊNCIAS	35

1 INTRODUÇÃO

O avanço das tecnologias fez com que o mundo todo ficasse conectado por meio da internet. Com o passar dos anos, o montante de dados aumenta exponencialmente e a população não é mais reconhecível sem aparelhos eletrônicos. A rápida evolução das tecnologias da informação faz com que o nível de qualidade dos serviços de comunicações se mantenha em patamares elevados e, assim, os usuários de serviços de telecomunicações possam desfrutar de conexões rápidas e altas qualidades de serviços de áudio e vídeo.

As comunicações ópticas são de suma importância para a evolução dos sistemas de comunicações modernos. Todo o *backbone* global é formado por milhares de quilômetros de fibras ópticas e, de acordo com (CISCO; AFFILIATES, 2019), o tráfego global anual da rede IP chegará a 4,8 zettabytes até o ano de 2022.

Para suprir a demanda crescente na taxa de transmissão de dados, as redes de comunicações precisam recorrer à comunicação via fibras ópticas por ser a tecnologia mais rentável e mais indicada para transmissão de altos volumes de dados. Destaca-se, nas comunicações ópticas, a fibra monomodo (*single mode fiber* - SFM), tecnologia de fibra padrão utilizado para a transferência de dados entre longas distâncias (> 1000 km), podendo transmitir cerca de 100 Terabits/s (12,5 Terabytes/s) (WINZER; ESSIAMBRE, 2006).

O Desenvolvimento de novos algoritmos de processamento digital de sinais possibilitaram a transmissão de grande volume de dados (DJORDJEVIC; VASIC, 2010). Os sistemas coerentes utilizam não apenas a amplitude, mas também a frequência e fase da portadora para codificar a informação no transmissor. Em tais sistemas, para recuperar a informação transmitida, o receptor deve ser capaz de acessar a frequência e a fase da portadora transmitida de forma síncrona. Para tanto, é necessário o uso de um oscilador local e um *front-end* coerente. O uso da detecção coerente permite que os receptores utilizem métodos eficientes de PDS que possibilitam a compensação de distorções impostas pela fibra óptica e pela imperfeição das fontes laser utilizadas na comunicação, o que, por sua vez, possibilita o uso de técnicas avançadas de modulação, como as utilizadas em comunicações sem fio. O uso de técnicas avançadas de modulação e codificação resulta num aumento das taxas de transmissão. É ilustrado no diagrama da Fig. 1 um sistema comum de comunicações coerentes.

O emprego da detecção coerente aumenta o custo dos receptores ópticos, de forma que seu uso comercial só é viável economicamente em sistemas de comunicações ópticas à longa distância, onde a alta concentração de tráfego leva a uma redução do custo por bit transmitido.

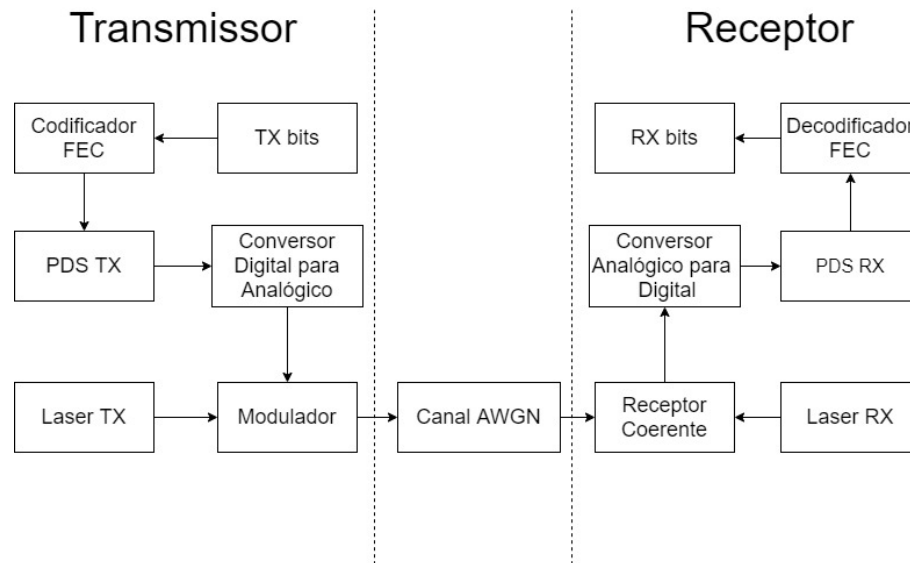


Figura 1 – Diagrama de um sistema comum de comunicações coerentes. Fonte autoral.

Para redes ópticas de curta distância, a utilização da Detecção Direta (DD) ainda é a opção mais viável economicamente, mesmo com as limitações que a mesma impõe às taxas de transmissão alcançáveis nesses sistemas.

1.1 OBJETIVOS

Tendo em vista a necessidade de técnicas de recepção e detecção de sinais, o trabalho tem como objetivo o estudo e implementação de técnica de processamento digital de sinais (PDS) utilizando algoritmos de aprendizado de máquina, baseados em redes neurais artificiais (RNA), para detecção de fase de sinais ópticos por detecção direta (DD).

2 FUNDAMENTAÇÃO TEÓRICA

2.1 TRANSMISSOR COERENTE DE KK

Um sistema óptico coerente genérico, como o representado pelo diagrama da Fig. 1, em que uma portadora óptica, gerada por um laser de onda contínua, é modulada por uma sequência de bits de informação. O sinal é transmitido por um enlace de fibra óptica e é demodulado com o auxílio de um laser oscilador local (LO), de mesma frequência da portadora.

O estado da arte atual acerca de comunicações ópticas coerentes utilizam modulação em amplitude, fase, polarização e multiplexação para a transmissão da informação. Os principais formatos de modulação presentes no mercado, até meados de 2016, são PSK binário, 4 e 16 QAM, possibilitando taxas de transmissão de 50, 100 e 200 Gb/s, respectivamente (AGRELL et al., 2016).

O problema presente nos sistemas coerentes está relacionado à recuperação de fase dos sinais recebidos. Para isso, os sistemas coerentes necessitam um *front-end* complexo e custoso para que, ao final de todo o processo, a informação contida na fase do sinal seja recuperada.

O receptor auto-coerente de Kramers-Kronig (KK) é implementado para resolver o problema da recuperação da fase do sinal óptico recebido por DD, utilizando *front-end* menos complexo. O sinal recebido por DD contém apenas informação das amplitudes do sinal original. Logo, é necessário que o algoritmo de KK seja capaz de processar esse sinal recebido e, assim, recuperar a fase do sinal original e, com isso, obter o restante da informação contida no sinal original (MECOZZI et al., 2016). Para isso o sinal recebido precisa respeitar a condição de sinal de fase mínima, que apresenta relação direta entre as amplitudes e as fases do sinal.


2.1.1 SINAL DE FASE MÍNIMA

Para que a recuperação da fases de sinais complexos seja feita apenas com as amplitudes destes sinais, é necessário que a condição de fase mínima seja respeitada. Obedecer a condição de sinal de fase mínima se faz necessário para que haja relação direta entre suas amplitudes e fases do sinal recebido. Logo, o sinal complexo $s(t)$, contido entre as frequências $-B/2$ e $B/2$, seja processado da seguinte forma:

$$h(t) = A + s(t)e^{-j\pi Bt}$$

Em que A é uma constante. Para que o sinal $h(t)$ obedeça a condição de fase mínima, é

necessário um valor de $|A|$ suficientemente grande, tal que a trajetória dos vetores complexos do sinal $h(t)$ não circulem a origem (MECOZZI et al., 2016). São apresentados na Fig. 2 dois sinais de fase mínima, sendo que um não obedece a condição.



(a) Sinal que não obedece a condição de fase mínima. (b) Sinal que obedece a condição de fase mínima.

Figura 2 – Geração de sinais de fase mínima. Fonte autoral.

Logo, quando $h(t)$ é um sinal de fase mínima, suas fase e amplitude estão unicamente relacionadas pela transformada de Hilbert (MECOZZI et al., 2016):

$$\Phi(\omega) = j \text{sign}(\omega) \mathcal{F} \{ \log[\|h(t)\|] \}$$

Em que a fase do sinal recebido é dada por $\Phi(\omega)$, $\text{sign}(\omega)$ é a função sinal, \mathcal{F} indica a transformada de Fourier e $\|h(t)\|$ representa a norma do sinal de fase mínima. Com isso, tem-se a relação entre as fases do sinal recebido e as suas amplitudes.

O valor de A está relacionado com a relação entre as potências do sinal e da portadora (*Carrier-to-Signal Power Ratio* - CSPR). Logo, o valor de CSPR escolhido é de suma importância para a geração do sinal de fase mínima.

Esse receptor de KK assume que o campo elétrico recebido é dado por $E_s(t)$, contido na largura de banda B . O LO é um laser de onda contínua na qual a amplitude é dada por E_L0 e de mesma frequência do sinal recebido. O campo elétrico que incide no fotodiodo é dado por $E(t) = E_s(t) + E_0 \exp^{-j\pi Bt}$ e a fotocorrente é dada por $I = |E(t)|^2$.

2.2 REDES NEURAIS

Redes Neurais Artificiais (*Artificial Neural Networks* - ANN) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes

e que adquirem conhecimento através da experiência (CARVALHO, 2009). Elas são classificadas em três tipos: Redes neurais artificiais, convolucionais e recorrentes.

As redes neurais artificiais (RNA) são compostas por estruturas simples conhecidas como perceptrons, que são relacionadas aos neurônios dos seres vivos (por isso os perceptrons também são chamados de neurônios). Como pode ser visto na Fig. 3, o perceptron é uma estrutura que processa uma determinada quantidade de valores de entrada (X_1 , X_2 e X_3) de acordo com uma determinada função de ativação para que, ao final, o perceptron informe o valor processado como saída (RUSSELL; NORVIG, 2010). A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos.




Figura 3 – Diagrama ilustrativo de um perceptron. Fonte autoral

Cada entrada tem sua devida importância no processo, traduzida matematicamente como um peso (P_1 , P_2 e P_3), e a rede neural atualiza esses pesos a cada iteração de treinamento. Os valores de entrada são então multiplicados por esses pesos e são processadas pela função de ativação presente nos neurônios.

As principais funções de ativação conhecidas e utilizadas são as funções linear e ReLu (Rectified Linear Unit). Os gráficos para essas duas funções de ativação estão presentes na Fig. 4.

A rede neural pode ser estruturada de forma a ter mais de uma camada. As camadas que ficam entre as camadas de entrada e saída da rede neural são conhecidas como camadas ocultas, como visto na Fig. 5 e têm o trabalho de refinar o processamento dos dados inseridos na rede neural.

2.2.1 Treinamento supervisionado

O treinamento supervisionado do modelo de RNA utilizado, consiste em ajustar os pesos e os limiares de suas unidades para que a classificação desejada seja obtida (CARVALHO, 2009).




Figura 4 – Gráfico das funções de ativação utilizadas no trabalho. Fonte autoral.

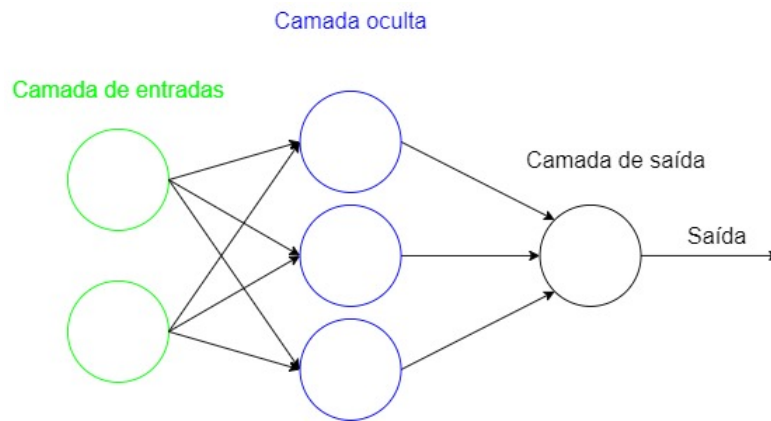


Figura 5 – Diagrama ilustrativo de uma RNA multicamada.

Os ajustes dos pesos e limiares são feitos à cada época de treinamento da RNA, seguindo a função de erro desejada.

Para isso, o conjunto de dados utilizado para o treinamento da rede neural precisa ser dividido entre os conjunto de treinamento e conjunto de validação. A cada época de treinamento, a RNA é testada com um conjunto de dados diferente para evitar sobreajuste (*overfitting*), em que o modelo matemático presente na RNA está ajustado para a predição do conjunto de treinamento de tal forma que o desempenho da RNA se torna ineficaz ao analisar novos conjuntos de dados.

A função de erro utilizada para situações em que o dado de saída da RNA é um número real é a função de erro médio quadrático (*Mean Squared Error - MSE*), que avalia a média quadrática da norma entre os valores de referência e os valores encontrados pela RNA. Essa função de erro serve para avaliar a convergência das RNAs, visto que a diminuição do MSE indica que a RNA está conseguindo recuperar o valor de referência com menor distorção.

Com esse comportamento, é possível treinar a RNA para atuar em situações previsíveis

e com alto nível de correlação e por isso ele pode ser utilizado para a recuperação de fase dos sinais QAM, já que existe a relação direta entre as amplitudes, que servirão de entradas para RNA, e as fases pela condição de sinal de fase mínima.

3 ESCOPO DO PROBLEMA E SOLUÇÃO PROPOSTA

O trabalho proposto tem como objetivo analisar a implementação e resultado de RNA utilizada para a recuperação de fase de sinais QAM transmitidas através do canal óptico com AWGN. Logo, a RNA receberá como entradas as amplitudes dos sinais QAM de fase mínima a fim de prover a fase correspondente de cada símbolo recebido.

3.1 ALGORITMO PROPOSTO

Este trabalho propõe um algoritmo de aprendizado profundo que processa as amplitudes de um sinal de fase mínima a fim de recuperar as fases deste sinal de entrada. Para isso, foram implementadas três RNAs unidimensionais, com diferentes valores de entradas, a fim de analisar e comparar o desempenhos de diferentes arquiteturas de RNAs para a solução do problema de recuperação de fase.

As três RNAs estão estruturadas da seguinte forma:

- Camada de entradas com 128, 256 e 512 entradas
- Duas camadas densas internas com função de ativação ReLu
- Camada de saída com função de ativação linear

Para a construção, treinamento e validação das RNAs, foram utilizados os *framework* keras (CHOLLET et al., 2015), biblioteca que faz parte do TensorFlow (ABADI et al., 2015).

O diagrama de blocos da RNA de 256 entradas é apresentado na Fig. 6.

Como mostrado na Fig. 6, o conjunto de dados contendo as amplitudes é inserido na RNA, processado e refinado pelas duas camadas internas de 16 e 4 neurônios e, por fim, a fase correspondente ao sinal de entrada é esperado na saída da RNA.

A função de erro utilizada no treinamento das RNAs para avaliar a convergência dos algoritmos foi a função MSE, visto que a fase do sinal a ser recuperada é um sinal real.

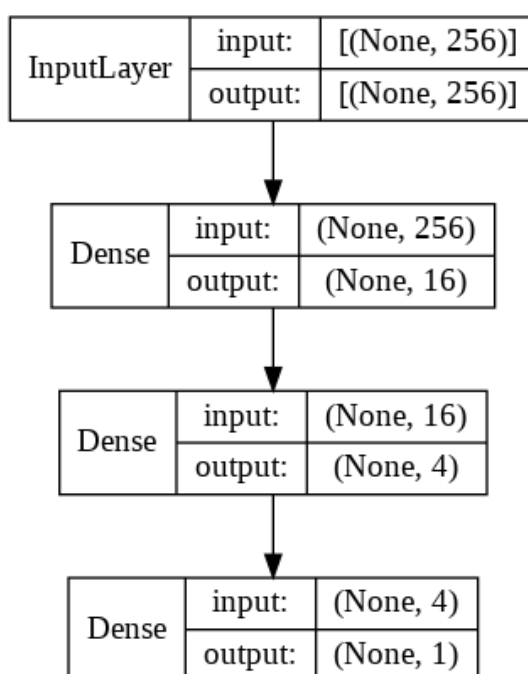


Figura 6 – Diagrama de blocos da rede neural com 256 entrada feito pelo *framework* keras.

4 MATERIAL E MÉTODOS

Como definido na seção de objetivos, o trabalho teve foco no estudo e implementação de técnica de PDS utilizando algoritmos de aprendizado de máquina, baseados em RNA, para a detecção de fase de sinais ópticos por DD. Neste capítulo serão demonstrados as ferramentas utilizadas para as simulações e obtenção dos resultados.

Para isso, foram utilizadas as bibliotecas QAMpy (SCHRODER; MAZUR, 2019), para implementação e simulação dos sinais e canal óptico, keras (CHOLLET et al., 2015) para implementação e treinamento da RNA proposta e as bibliotecas numpy (HARRIS et al., 2020), scipy (VIRTANEN et al., 2020), e matplotlib (HUNTER, 2007) para para a manipulação e visualização dos dados simulados.

4.1 SIMULAÇÃO DA TRANSMISSÃO QAM

Utilizando a biblioteca QAMpy, foi possível implementar o canal óptico com AWGN utilizado para as simulações. O sinal QAM $E(t)$ é gerado com amplitude $|E(t)|$ e fase original $\phi(t)$ e um pulso formatador cosseno levantado com *rolloff* igual a 0.05 é utilizado para suavizar o sinal. Com isso, o sinal é transmitido através de um canal AWGN, a biblioteca QAMpy adiciona ruído gaussiano ao sinal a fim de que o sinal seja recebido com o valor de SNR desejado. O sinal recebido é então transformado em sinal de fase mínima a partir de um tom senoidal do LO, com valor DC escolhido de acordo com CSPR escolhido pelo usuário. O sinal é então recebido por DD, em que as suas amplitudes são utilizadas pela RNA para a recuperação da fase do sinal recebido, $\phi'(t)$. O sinal complexo recebido é então gerado com a utilização das amplitudes do sinal e a fase recuperada pela RNA e, por fim, o sinal é passado por um filtro casado com mesmo *rolloff* do filtro formatador de pulso. O processo de simulação está ilustrado no diagrama da Fig. 7.

A figura de mérito utilizada para a comparação e validação do canal simulado foi a BER e, para isso, foi analisada a transmissão de sinais com modulações distintas: 16 QAM e 64 QAM. São ilustradas nas Fig. 8a e Fig. 8b a comparações entre a BER teórica e a BER obtida pelas simulações de transmissão de sinais 16 e 64 QAM pelo canal AWGN.

Ao analisar os gráficos, nota-se que o ambiente de simulação escolhido para o trabalho foi previamente validado, pois garante as especificações de um canal com ruído aditivo gaussiano ideal para transmissão de sinais QAM.

O sinal recebido é processado e se transforma num sinal de fase mínima com a CSPR

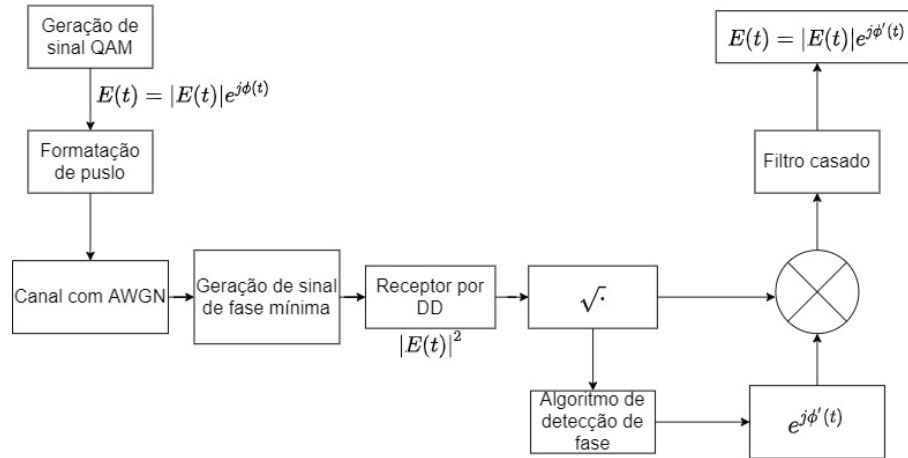


Figura 7 – Procedimento utilizado na simulação.

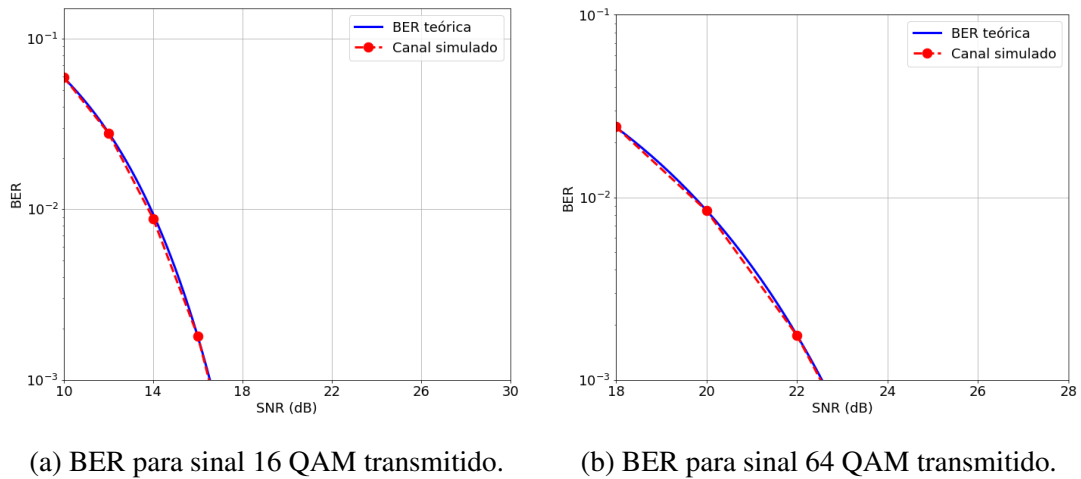


Figura 8 – Análise comparativa entre as BER teórica para o canal AWGN e do canal simulado para transmissão de sinais QAM.

desejada para as análises e, só então, é detectado por DD e as amplitudes correspondentes aos símbolos recebidos são processados pela rede neural a fim de que as fases dos vetores recebidos sejam recuperadas. Foram utilizados 100 mil símbolos para a obtenção da BER, logo a curva se mostra confiável apenas para valores de BER até 10^{-5} .

4.2 TREINAMENTO DA REDE NEURAL

Para o treinamento supervisionado das redes neurais, foram utilizados sinais de fase mínima, com modulação 64 QAM, com as seguintes especificações:

- Fator de sobre amostragem = 2, 4 e 8 SPS,
- Rolloff do filtro formatador de pulso = 0.05
- Número de símbolos: 200000

- $CSPR \in [4, 17]dB$, sendo CSPR inteiro
- $SNR = 50$ dB

É ilustrado na Fig. 9 a constelação do sinal QAM de fase mínima utilizado para o treinamento das redes neurais propostas para este trabalho.




Figura 9 – Constelação do sinal QAM de fase mínima, com CSPR igual a 17 dB, utilizado para o treinamento das redes neurais.

As amplitudes foram utilizadas como entradas para a RNA como mostrado na Fig. 10. Das M amplitudes utilizadas na RNA, sendo M igual a 128, 256 ou 512, a RNA recupera a fase da N -ésima amostra do sinal recebido.




Figura 10 – Processo de recuperação de fase feito pela RNA.

Os código fonte da implementação do algoritmo, modelos das redes neurais treinadas, resultados e figuras estão presentes no repositório do trabalho (MATOS, 2021).

5 RESULTADOS

O capítulo anterior indica a metodologia utilizada para a obtenção dos resultados das simulações deste trabalho. Os resultados permitem avaliar o desempenho da rede neural proposta, frente ao desempenho do algoritmo KK proposto por (MECOZZI et al., 2016), tendo como objetivo primário a obtenção de uma BER inferior à 10^{-2} , limite típico permitido pelos códigos corretores (limite FEC) num sistema real em operação.

5.1 DETECÇÃO DE SINAIS 64-QAM

Os sinais foram recebidos em três situações diferentes de amostragem: com 2, 4 e 8 SpS. As subseções seguintes apresentam os resultados para todas as conformações, utilizando CSPR igual a 17 dB, valor extrapolado para simulações primárias.


São demonstradas nas Fig. 11a, 11b e 11c as curvas de BER versus a SNR do sinal recebido e amostrado à 2 SpS, sendo processados tanto pela rede neural, quanto pelo algoritmo de KK. As figuras ainda apresentam o limite FEC (preto tracejado) e a curva de BER teórica para a recepção de sinais 64 QAM transmitidas pelo canal AWGN.

Analisando as Fig. 11a, 11b e 11c, constata-se que o modelo, assim como o algoritmo de KK, não alcança a BER necessária para atingir o limite FEC, nas condições de simulação utilizadas. Porém, nota-se que a rede neural proposta apresenta desempenho comparável ao desempenho do algoritmo de KK.


São apresentadas nas Fig. 12a, 12b e 12c as curvas de BER versus a SNR do sinal recebido e amostrado à 4 SpS, sendo processados tanto pela rede neural, quanto pelo algoritmo de KK. As figuras ainda apresentam o limite FEC (preto tracejado) e a curva de BER teórica para a recepção de sinais 64 QAM.

Analisando as Fig. 12a, 12b e 12c, constata-se que o modelo, assim como o algoritmo de KK, alcança a BER necessária para atingir o limite FEC, nas condições de simulação utilizadas. Nota-se também que a rede neural proposta apresenta desempenho comparável ao desempenho do sistema de KK para sinais recuperados pelas redes neurais que apresentam 256 e 512 entradas.


As curvas também indicam que a rede neural é sensível à variação da quantidade de entradas suportadas pelas redes neurais. Resultados semelhantes foram obtidos para a recepção de sinais amostrados à 8 SpS



(a) Rede neural treinada com 128 entradas.




(b) Rede neural treinada com 256 entradas.

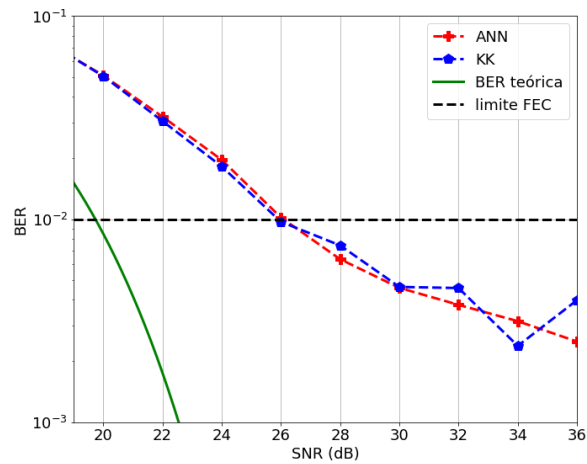


(c) Rede neural treinada com 512 entradas.

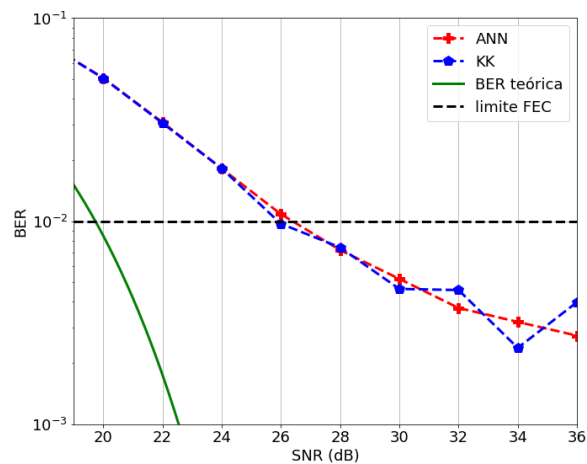
Figura 11 – Curvas da BER vs SNR para sinais 64 QAM recebidos à 2 SpS com CSPR igual a 17 dB. Redes neurais treinadas com diferentes valores de entradas.



(a) Rede neural treinada com 128 entradas.



(b) Rede neural treinada com 256 entradas.



(c) Rede neural treinada com 512 entradas.

Figura 12 – Curvas da BER vs SNR para sinais 64 QAM recebidos à 4 SpS com CSCR igual a 17 dB. Redes neurais treinadas com diferentes valores de entradas.

5.1.1 Comparação entre sinais com diferentes sobre amostragens

São demonstradas na Fig. 13 demonstra as curvas de BER vs SNR para sinais 64 QAM recebidos com CSCR igual a 10 dB. As curvas pontilhadas apresentam o desempenho da rede

neural com 256 entradas.




Figura 13 – Comparação entre curvas da BER vs SNR para sinais 64 QAM recebidos à diferentes valores de sobre amostragem e 10 dB de CSRR. Rede neural treinada com 256 entradas.

Analisando a Fig. 13, constata-se que a recuperação da fase de sinais detectados por DD é sensível à taxa de amostragem e após sobre amostragem de 4 SpS o desempenho da recuperação não apresenta melhora significativa.

5.1.2 Comparação entre sinais com diferentes CSRRs

Analisando a Fig. 14, constata-se que tanto o algoritmo KK quanto a rede neural são sensíveis ao valor de CSRR do sinal recebido, mostrando que o desempenho dos modelos é melhorado com o aumento da CSRR. Foi utilizada a RNA de 256 entradas e resultados semelhantes foram observados para sinais amostrados à 2 e 8 SpS.

5.2 DETECÇÃO DE SINAIS 16-QAM

5.2.1 Reutilização das redes neurais

Para a recuperação da fase de sinais 16 QAM, os mesmos modelos treinados com sinais 64 QAM foram utilizados. Os resultados mostram que as redes neurais podem também ser utilizadas para a recepção de sinais com ordem de modulação menor que os sinais utilizados para o treinamento das redes.




Figura 14 – Curvas da BER vs SNR para sinal 64 QAM recebido. Rede neural treinada com 256 entradas e sinais amostrados à 4 SpS.

São demonstradas nas Fig. 15a, 15b e 15c as curvas de BER versus a SNR do sinal recebido e amostrado à 2 SpS, sendo processados tanto pelas RNAs, quanto pelo algoritmo de KK. As figuras ainda apresentam o limite FEC (preto tracejado) e a curva de BER teórica para a recepção de sinais 16 QAM.


Analisando as Fig. 15a, 15b e 15c, constata-se que o modelo, assim como o algoritmo de KK, alcança a BER necessária para atingir o limite FEC, nas condições de simulação utilizadas. Nota-se também que a rede neural proposta neste trabalho apresenta desempenho comparável ao desempenho do sistema de KK.

A mesma análise foi feita para a recepção de sinais amostrados à 4 e 8 SpS e resultados semelhantes foram obtidos.


5.2.2 Comparação entre sinais com diferentes sobre amostragens

São demonstradas na Fig. 16 as curvas de BER vs SNR para sinais 16 QAM recebidos com CSPR igual a 10 dB. As curvas pontilhadas apresentam o desempenho da rede neural com 256 entradas.


Analisando a Fig. 16, constata-se que a recuperação da fase de sinais, detectados por DD, é sensível à taxa de amostragem e após sobre amostragem de 4 SpS o desempenho da recuperação não apresenta melhora significativa. A Fig. 16 demonstra ainda que, para o sinal com sobre amostragem de 2 SpS, a rede neural obteve melhor desempenho que o algoritmo de



(a) Rede neural treinada com 128 entradas.



(b) Rede neural treinada com 256 entradas.



(c) Rede neural treinada com 512 entradas.

Figura 15 – Curvas da BER vs SNR para sinais 16 QAM recebidos com 17 dB de CSPR. Redes neurais treinadas com diferentes valores de entradas

KK.




Figura 16 – Curvas da BER vs SNR para sinal 16 QAM recebido com 10 dB de CSCR. Rede neural treinada com 256 entradas.

5.2.3 Comparação entre sinais com diferentes CSCRs




Figura 17 – Curvas da BER vs SNR para sinal 16 QAM recebido à 2 SpS. Rede neural treinada com 256 entradas.

Analisando as Fig. 17, constata-se que a recuperação da fase de sinais, detectados por DD, é sensível também à variação da CSCR. Nota-se também que o desempenho da rede neural não apresenta melhora significativa após 9 dB de CSCR. Para essa simulação, foi utilizada a RNA com 256 entradas.

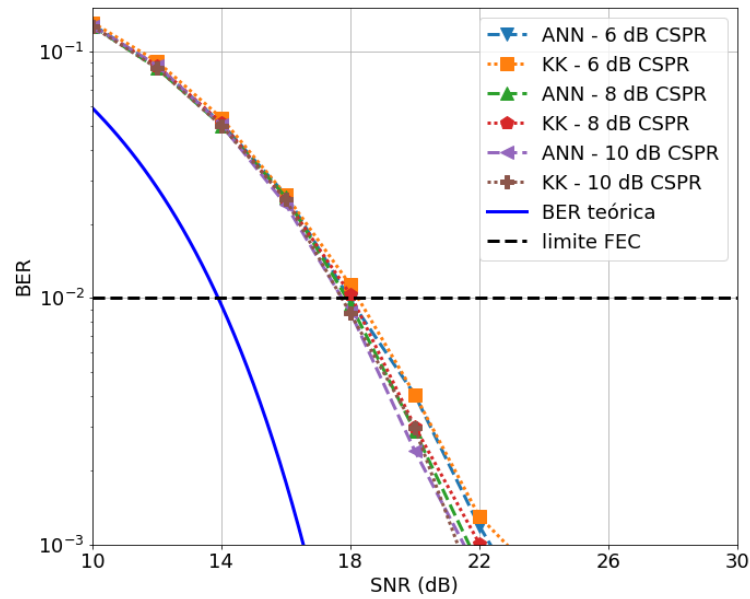


Figura 18 – Curvas da BER vs SNR para sinal 16 QAM recebido à 4 SpS. Rede neural treinada com 256 entradas.

São demonstradas na Fig. 17 curvas em que o desempenho da rede neural é superior ao desempenho do algoritmo de KK. A figura mostra que, para sinais com 5 dB de CSCR, a penalidade entre a BER obtida pela simulação com a rede neural e o algoritmo KK foi maior que 10 dB.

É apresentado na Fig. 18 que a variação do CSCR não apresenta melhora significativa para sinais amostrados à 4 SpS e resultados semelhantes foram observados para sinais amostrados à 8 SpS.

6 CONCLUSÃO

Com a crescente demanda na taxa de transmissão de dados, custo, complexidade e qualidade dos sistemas de recepção óptica são fatores determinantes para a escolha da arquitetura de recepção a ser utilizada. Portanto, sistemas coerentes são apresentados como o estado da arte para as comunicações ópticas, por conseguir alcançar maior eficiência espectral.

Logo, análises e implementações de técnicas de recepção de sinais com técnicas de modulação mais avançadas precisam ser feitas, assim como a técnica dos receptores de KK.

Neste trabalho, observa-se que o algoritmo proposto obteve resultados comparáveis aos apresentados pelo algoritmo de KK para a recepção de sinais 16 e 64 QAM transmitidos via canal com AWGN, sendo superior em casos com menor fator de sobre amostragem e menor CSPR para sinais 16 QAM.

Apesar dos resultados favoráveis, ainda é necessário avaliar se o algoritmo proposto é compatível com modelos de transmissão mais complexos, com distorções além do AWGN, e analisar o impacto no desempenho da RNA.

Os objetivos futuros do trabalho são aumentar o grau de complexidade das simulações, inserindo ao sinal recebido distorções além do AWGN, analisar novas arquiteturas de RNAs que possam causar impacto positivo no desempenho das simulações, além de analisar o custo computacional. Trabalhos paralelos para a implementação e validação de resultados experimentais serão seguidos.

REFERÊNCIAS

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDIO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>.
- AGRELL, E.; KARLSSON, M.; CHRAPLYVY, A. R.; RICHARDSON, D. J.; KRUMMRICH, P. M.; WINZER, P.; ROBERTS, K.; FISCHER, J. K.; SAVORY, S. J.; EGGLETON, B. J.; SECONDINI, M.; KSCHISCHANG, F. R.; LORD, A.; PRAT, J.; TOMKOS, I.; BOWERS, J. E.; SRINIVASAN, S.; BRANDT-PEARCE, M.; GISIN, N. Roadmap of optical communications. **Journal of Optics**, IOP Publishing, v. 18, n. 6, p. 063002, may 2016. Disponível em: <<https://doi.org/10.1088/2040-8978/18/6/063002>>.
- CARVALHO, A. P. de Leon F. de. **Redes Neurais Artificiais**. 2009. <<https://sites.icmc.usp.br/andre/research/neural/>>.
- CHOLLET, F. et al. **Keras**. 2015. <<https://keras.io>>.
- CISCO; AFFILIATES. Cisco visual network index: Forecast and trends, 2017-2022. 2019.
- DJORDJEVIC, I.; VASIC, W. R. e B. **Coding for Optical Channels**. [S.l.]: Springer, 2010.
- HARRIS, C. R.; MILLMAN, K. J.; WALT, S. J. van der; GOMMERS, R.; VIRTANEN, P.; COURNAPEAU, D.; WIESER, E.; TAYLOR, J.; BERG, S.; SMITH, N. J.; KERN, R.; PICUS, M.; HOYER, S.; KERKWIJK, M. H. van; BRETT, M.; HALDANE, A.; RÍO, J. Fernández del; WIEBE, M.; PETERSON, P.; GÉRARD-MARCHANT, P.; SHEPPARD, K.; REDDY, T.; WECKESSER, W.; ABBASI, H.; GOHLKE, C.; OLIPHANT, T. E. Array programming with NumPy. **Nature**, v. 585, p. 357–362, 2020.
- HUNTER, J. D. Matplotlib: A 2d graphics environment. **Computing in Science & Engineering**, IEEE COMPUTER SOC, v. 9, n. 3, p. 90–95, 2007.
- MATOS, V. A. **Detecção de fase utilizando aprendizado de máquina**. 2021. <https://github.com/Matos-V/TCC_phase_detection_with_ML>.
- MECOZZI, A.; ANTONELLI, C.; SHTAIF, M. Kramers–kronig coherent receiver. **Optica**, OSA, v. 3, n. 11, p. 1220–1227, Nov 2016. Disponível em: <<http://www.osapublishing.org/optica/abstract.cfm?URI=optica-3-11-1220>>.
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3. ed. [S.l.]: Prentice Hall, 2010.
- SCHRODER, J.; MAZUR, M. **QAMPy a DSP chain for optical communications**. 2019.
- VIRTANEN, P.; GOMMERS, R.; OLIPHANT, T. E.; HABERLAND, M.; REDDY, T.; COURNAPEAU, D.; BUROVSKI, E.; PETERSON, P.; WECKESSER, W.; BRIGHT, J.; van der Walt, S. J.; BRETT, M.; WILSON, J.; MILLMAN, K. J.; MAYOROV, N.; NELSON, A.

R. J.; JONES, E.; KERN, R.; LARSON, E.; CAREY, C. J.; POLAT, İ.; FENG, Y.; MOORE, E. W.; VanderPlas, J.; LAXALDE, D.; PERKTOLD, J.; CIMRMAN, R.; HENRIKSEN, I.; QUINTERO, E. A.; HARRIS, C. R.; ARCHIBALD, A. M.; RIBEIRO, A. H.; PEDREGOSA, F.; van Mulbregt, P.; SciPy 1.0 Contributors. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. **Nature Methods**, v. 17, p. 261–272, 2020.

WINZER, P. J.; ESSIAMBRE, R.-J. Advanced modulation formats for high-capacity optical transport networks. **Journal of Lightwave Technology**, v. 24, n. 12, p. 4711–4728, 2006.