

UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
CURSO DE GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES

Emanuel Savegnago Maziero

**ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL CONJUNTA EM UM  
SISTEMA DE MULTIPLEXAÇÃO ESPACIAL MIMO-OFDM POR REDES  
NEURAS ARTIFICIAIS**

Santa Maria, RS  
2024

Emanuel Savegnago Maziero

**ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL CONJUNTA EM UM SISTEMA DE MULTIPLEXAÇÃO ESPACIAL MIMO-OFDM POR REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Telecomunicações, Área de Concentração em Telecomunicações, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Engenheiro de Telecomunicações em Engenharia de Telecomunicações**. Defesa realizada por videoconferência.

Orientador: Prof. Samuel Tumelero Valduga

Santa Maria, RS  
2024



**Emanuel Savegnago Maziero**

**ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL CONJUNTA EM UM SISTEMA DE MULTIPLEXAÇÃO ESPACIAL MIMO-OFDM POR REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Telecomunicações, Área de Concentração em Telecomunicações, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Engenheiro de Telecomunicações em Engenharia de Telecomunicações**.

**Aprovado em - de julho de 2024:**

---

**Samuel Tumelero Valduga, Dr. (UFSM)**  
**(Presidente/Orientador)**

---

**Candice Muller, Dr. (UFSM)**

---

**Natanael Rodrigues Gomes, Dr. (UFSM)**

Santa Maria, RS  
2024

## DEDICATÓRIA

Dedico esse trabalho à minha mãe, Cirlene e ao meu pai, João Viane, que de diferentes formas me ensinaram valores que carregarei para sempre e que me apoiam de forma incondicional, à minha dinda Patrícia, que é praticamente uma segunda mãe, ao meu tio Adriano e minha tia Ana Júlia, que me ofereceram pouso e foram essenciais para esse trabalho ter sido concluído no tempo que foi, à minha companheira Isabela, que acompanhou de perto toda essa jornada e sempre ofereceu apoio, e à todos meus familiares e amigos próximos, que de alguma forma estiveram comigo.

## AGRADECIMENTOS

Para todos que de alguma forma me ajudaram, apoiaram e incentivaram, direta e indiretamente na minha trajetória, muito obrigado. Aos meus pais, que sempre estiveram diretamente envolvidos suportando meus passos, um muito obrigado especial. Tudo de bom que eu sou ou for, terá bastante de vocês.

Um agradecimento especial ao professor Samuel Tumelero Valduga, meu orientador, que mostrou para mim o mundo da pesquisa científica e me fez conhecer o tema que dá título a esse trabalho. Obrigado pela compreensão e por toda ajuda, seja nos momentos bons ou ruins.

Quero agradecer também aos vários amigos que conheci durante a graduação, tanto os que não falo mais, quanto os que ainda tenho contato, em especial aos meus colegas do curso de Engenharia de Telecomunicações: Élter, Luis Felipe e Pedro Henrique, os guerreiros que estiveram comigo desde que entrei no curso e até seu fim, entre dificuldades, brincadeiras, discussões e risadas.

À minha companheira e namorada Isabela, que o acaso me fez encontrar nesse mesmo curso e que me acompanhou em todos altos e baixos dessa caminhada pela engenharia. Não consigo imaginar como seria sem você e sem o seu amor.

Aos que me fizeram companhia como membros do GPSCom, onde compartilhamos as felicidades e tristezas da graduação sem se preocupar, pois todos sabiam que ali era um ambiente que além de abrigar muitos pesquisadores, abrigava muitos amigos.

E não posso deixar de agradecer aos inúmeros professores que me mostraram o caminho do conhecimento nas mais variadas disciplinas e áreas do conhecimento. Sem professores, eu jamais poderia ter sido um aluno. Muito obrigado.

A vida passa muito rápido. Se você não parar e olhar ao redor de vez em quando, pode acabar perdendo-a.

(Ferris Bueller)

## RESUMO

# ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL CONJUNTA EM UM SISTEMA DE MULTIPLEXAÇÃO ESPACIAL MIMO-OFDM POR REDES NEURAIS ARTIFICIAIS

AUTOR: Emanuel Savegnago Maziero

Orientador: Samuel Tumelero Valduga

A comunicação sem fio moderna enfrenta grandes desafios para lidar com os complexos canais de rádio, especialmente em cenários urbanos com muitos obstáculos e múltiplos percursos que resultam em símbolos superpostos, interferência destrutiva e ecos dos sinais transmitidos. Isso faz com que o sistema tenha problemas de interferência intersimbólica, o que, por sua vez, causa erros de bits e símbolos, degradando a performance do sistema. A estimação e a equalização do canal são as partes da recepção do sinal responsáveis por entender como o canal distorceu o sinal e retirar esse efeito. Os sistemas atuais da quinta geração de internet móvel (5G) são poderosos e complexos, e o crescimento desses sistemas permitiu o avanço das pesquisas e o surgimento dos sistemas MIMO-OFDM (*Multiple Input Multiple Output Orthogonal Frequency Division Multiplexing*), que unem os sistemas de múltiplas antenas transmissoras e receptoras com a transmissão em subportadoras ortogonais em busca de aumentar a capacidade, eficiência espectral, velocidade e confiabilidade das transmissões. Nesse contexto, a proposta deste trabalho é abordar a questão da estimação e equalização de canal utilizando redes neurais artificiais capazes de realizar essas duas tarefas de forma conjunta em um sistema de multiplexação espacial MIMO-OFDM cuja transmissão é feita em um canal baseado em um modelo das normas do 5G. Essas redes neurais são treinadas *offline* e não usam necessitam do uso de pilotos. Os resultados dessa proposta mostram que as redes neurais conseguem superar as técnicas clássicas, até mesmo as pouco práticas como o *Minimum Mean Squared Error* (MMSE). A rede neural artificial complexa (RNC) teve os melhores resultados de *Bit Error Rate* (BER) em  $E_b/N_0 = 0$  e 5 dB, enquanto a RNAS se destacou em 10 dB, mantendo uma diferença pequena em relação ao MMSE em toda faixa de  $E_b/N_0$ . A rede neural artificial real (RNAR), por fim, superou as outras técnicas a partir de  $E_b/N_0 = 15$  dB. As redes neurais e o MMSE foram analisados em alguns cenários adversos a fim de verificar a robustez dessas soluções. Para simular um cenário onde há movimentação dos terminais receptores, foi adicionado o efeito Doppler, e para representar uma transmissão mais difícil, foi usado um canal com mais atrasos. Para analisar a degradação causada pela ISI, a transmissão foi feita com a ausência do prefixo cíclico OFDM. Os resultados mostram que, nesses cenários adversos, as redes geralmente performam melhor que o MMSE, exceto no caso do efeito Doppler.

**Palavras-chave:** Estimação de Canal. Equalização de Canal. MIMO. OFDM. Multiplexação Espacial. *Machine Learning*. Redes Neurais. Redes Neurais Complexas.

## ABSTRACT

### ARTIFICIAL NEURAL NETWORKS CHANNEL ESTIMATION AND EQUALIZATION IN A SPATIAL MULTIPLEXING MIMO-OFDM SYSTEM

AUTHOR: Emanuel Savegnago Maziero

ADVISOR: Samuel Tumelero Valduga

Modern wireless communication faces significant challenges in dealing with complex radio channels, especially in urban scenarios with many obstacles and multiple paths that result in overlapping symbols, destructive interference, and echoes of transmitted signals. This leads to inter-symbol interference problems, which in turn cause bit and symbol errors, degrading system performance. Channel estimation and equalization are the parts of signal reception responsible for understanding how the channel distorted the signal and removing this effect. The current fifth-generation mobile internet (5G) systems are powerful and complex, and their growth has allowed for advances in research and the emergence of MIMO-OFDM (Multiple Input Multiple Output Orthogonal Frequency Division Multiplexing) systems. These systems combine multiple transmitting and receiving antennas with transmission on orthogonal subcarriers to increase capacity, spectral efficiency, speed, and reliability of transmissions. In this context, the proposal of this work is to address the issue of channel estimation and equalization using artificial neural networks capable of performing these two tasks jointly in a MIMO-OFDM spatial multiplexing system, whose transmission is carried out in a channel based on a model of 5G standards. These neural networks are trained offline and do not use pilots. The results of this proposal show that neural networks can outperform classical techniques, including the less practical ones such as Minimum Mean Squared Error (MMSE). The complex artificial neural network (RNC) had the best Bit Error Rate (BER) results at  $E_b/N_0 = 0$  and 5 dB, while the RNAS stood out at 10 dB, maintaining a small difference compared to MMSE across the entire  $E_b/N_0$  range. The real artificial neural network (RNAR), finally, outperformed the other techniques from  $E_b/N_0 = 15$  dB. Neural networks and MMSE were analyzed in some adverse scenarios to verify the robustness of these solutions. To simulate a scenario where the receiver terminals are moving, the Doppler effect was added, and to represent a more difficult transmission, a channel with more delays was used. To analyze the degradation caused by ISI, the transmission was carried out without the OFDM cyclic prefix. The results show that, in these adverse scenarios, the networks generally perform better than MMSE, except in the case of the Doppler effect.

**Keywords:** Channel Estimation. Channel Equalization. MIMO. OFDM. Spatial Multiplexing. Machine Learning. Neural Networks. Complex-Valued Neural Networks.

## LISTA DE FIGURAS

Figura 1 – Seletividade em frequência da transmissão multi-portadora .....	18
Figura 2 – Espectro de potência da transmissão multi-portadora .....	19
Figura 3 – Ortogonalidade das subportadoras no domínio da frequência .....	20
Figura 4 – Ilustração do prefixo cíclico do símbolo OFDM .....	20
Figura 5 – Densidade Espectral de Potência Normalizada do Símbolo OFDM .....	22
Figura 6 – Esquemático do Sistema OFDM .....	22
Figura 7 – Resposta ao impulso do canal em um instante de tempo e resposta em frequência com desvanecimento seletivo em frequência .....	26
Figura 8 – Neurônio Artificial (Perceptron). .....	30
Figura 9 – Rede Neural Artificial ( <i>Multi-Layer Perceptron</i> ) .....	31
Figura 10 – Tipos de Arranjos de Pilotos em Sistemas OFDM. ....	36
Figura 11 – Sistema Proposto .....	40
Figura 12 – Treinamento .....	44
Figura 13 – Validação .....	45
Figura 14 – Desempenho de MSE das técnicas clássicas e redes neurais .....	46
Figura 15 – Desempenho de BER das técnicas clássicas e redes neurais .....	47
Figura 16 – Constelação de símbolos recebidas nas antenas receptoras usando o MMSE .....	48
Figura 17 – Constelação de símbolos recebidas nas antenas receptoras usando a RNAR .....	48
Figura 18 – Constelação de símbolos recebidas nas antenas receptoras usando a RNC .....	49
Figura 19 – Constelação de símbolos recebidas nas antenas receptoras usando a RNAS .....	49
Figura 20 – Desempenho de BER na Fase de Teste das Redes Neurais Artificiais ....	50
Figura 21 – Desempenho de BER das Redes Neurais Artificiais e do MMSE em um Cenário com Doppler .....	51
Figura 22 – Desempenho de BER das Redes Neurais Artificiais Treinadas para $E_b/N_0 =$ $20$ dB e Validadas para $E_b/N_0 \in [0, 15]$ dB .....	52
Figura 23 – Desempenho de BER das Redes Neurais Artificiais Treinadas para $E_b/N_0 =$ $0$ dB e Validadas para $E_b/N_0 \in [5, 20]$ dB .....	53
Figura 24 – Desempenho de BER das Redes Neurais Artificiais e do MMSE com Au- mento do <i>Delay Spread</i> .....	54
Figura 25 – Desempenho de BER das Redes Neurais Artificiais e do MMSE sem o Prefixo Cíclico do Símbolo OFDM .....	55

## LISTA DE TABELAS

TABELA 1 – Modelo de Canal TDL-A .....	28
TABELA 2 – Complexidade computacional da RNAR .....	32
TABELA 3 – Complexidade computacional da RNC .....	34
TABELA 4 – Complexidade computacional da RNAS .....	34
TABELA 5 – Parâmetros do Sistema MIMO-OFDM .....	42
TABELA 6 – Parâmetros do Canal Sem Fio .....	42
TABELA 7 – Parâmetros das Redes Neurais .....	43

## LISTA DE SIGLAS

OFDM	<i>Orthogonal Frequency-Division Multiplexing</i>
MIMO	<i>Multiple Input Multiple Output</i>
FDM	<i>Frequency Division Multiplexing</i>
ISI	<i>Intersymbol Interference</i>
3GPP	<i>3rd Generation Partnership Project</i>
TDL	<i>Tapped Delay-Line</i>
RNA	Rede Neural Artificial
RNAR	Rede Neural Artificial Real AWGN
	<i>Additive</i>
	<i>White</i>
	<i>Gaussian</i>
	<i>Noise</i>
FT	<i>Fourier Transform</i>
RMS	<i>Root Mean Square</i>
BW	<i>Bandwidth</i>
ICI	<i>Intercarrier Interference</i>
Tx	Transmissor
Rx	Receptor
CP	<i>Cyclic Prefix</i>
IFFT	<i>Inverse Fast Fourier Transform</i>
SISO	<i>Single Input Single Output</i>
MLP	<i>MultiLayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
RNC	Rede Neural Artificial Complexa
RNAS	Rede Neural Artificial Complexa com Ativação Separada
CSI	<i>Channel State Information</i>
LS	<i>Least Squares</i>
MMSE	<i>Minimum Mean Squared Error</i>
FFT	<i>Fast Fourier Transform</i>
LMMSE	<i>Linear Minimum Mean Squared Error</i>
$E_b/N_0$	Relação Energia de Bit por Densidade Espectral de Potência de Ruído
FPGA	<i>Field Programmable Gate Array</i>

## LISTA DE SÍMBOLOS

$k$	Índice de Subportadora
$\mathcal{K}$	Número de Subportadoras
$f_k$	Frequência na Subportadora $k$
$t$	Índice Temporal Contínuo
$n$	Índice Temporal Discreto
$T_s$	Duração do Símbolo OFDM
$\mathbf{q}$	Vetor de Símbolos Fonte
$T_d$	Duração do Símbolo Fonte
$F_{cs}$	Espaçamento entre Subportadoras
$N_{cp}$	Tamanho do Prefixo Cíclico
$N_d$	Número de Atrasos do Canal Multipercurso
$\mathcal{H}$	Resposta em Frequência do Canal
$\hat{\mathcal{H}}$	Resposta em Frequência do Canal Estimada
$\tau$	Índice de Atrasos do Canal
$\mathbf{s}$	Sinal Transmitido
$\mathbf{a}$	Ruído Gaussiano Branco Aditivo
$\sigma_w^2$	Variância do Ruído
$\mathbf{r}$	Sinal Recebido
$h$	Resposta em Tempo do Canal
$a_p$	Amplitude do Percurso $p$
$f_{D,p}$	Frequência Doppler do Percurso $p$
$\phi_p$	Fase do Percurso $p$
$\tau_p$	Atraso de Propagação do Percurso $p$
$B$	Largura de Banda

$v$	Velocidade do Terminal
$c$	Velocidade da Luz
$f_c$	Frequência da Portadora
$\alpha_p$	Ângulo de Incidência de uma Onda em um Percurso p
$\rho$	Densidade Espectral de Potência
$\bar{\tau}$	Atraso Médio
$\tau_{max}$	Atraso Máximo
$\Omega_p$	Potência do Caminho p
$N_p$	Número de Percursos
$f_D$	Frequência Doppler
$f_{D_{max}}$	Frequência Doppler Máxima
$f_{D_s}$	Espalhamento Doppler
$T'_s$	Duração do Símbolo OFDM com Prefixo Cíclico
$i$	Símbolo OFDM i
$N_t$	Número de Antenas Transmissoras
$N_r$	Número de Antenas Receptoras
$\sum$	Somatório
$w$	Pesos Sinápticos de um Neurônio
$x$	Vetor de Entradas de um Neurônio ou Rede Neural
$b$	Bias de um Neurônio
$y$	Saída de um Neurônio
$d$	Saída Desejada de um Neurônio
$e$	Erro
$e$	Vetor de Erro
$l$	Camada de uma Rede Neural
$L$	Camada de Saída de uma Rede Neural

$I$	Número de Neurônios de uma Camada Escondida de uma Rede Neural
$W$	Matriz de Pesos Sinápticos de uma Rede Neural
$b$	Vetor de Bias de uma Rede Neural
$y$	Saída de uma Camada de uma Rede Neural após a Ativação
$v$	Saída de uma Camada de uma Rede Neural antes da Ativação
$J$	Função de Custo
$\mathcal{P}$	Índice Indicador de Portadora Piloto
$I$	Matriz Identidade
$\mathcal{F}$	Operador de FFT
$R$	Correlação
$\eta$	Taxa de Aprendizado dos Parâmetros da Rede Neural
$\Re$	Parte Real de um Número
$\Im$	Parte Imaginária de um Número
$\nabla$	Gradiente
$\beta$	Constante de Modulação
$\mathcal{C}$	Circularmente Complexo
$\mathcal{N}$	Distribuição Gaussiana
$f(\cdot)$	Função de Ativação Não-Linear
$f'(\cdot)$	Derivada da Função de Ativação Não-Linear
$\{\cdot\}^T$	Transposição de Matriz ou Vetor
$\{\cdot\}^{-1}$	Pseudo-Inversão de Matriz ou Vetor
$E\{\cdot\}$	Operador de Esperança Matemática
$\mathbb{Z}$	Conjunto dos Números Inteiros
$\mathbb{R}$	Conjunto dos Números Reais
$\mathbb{C}$	Conjunto dos Números Complexos
$\ \cdot\ _2$	Erro Médio Quadrático

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
1.1	OBJETIVOS .....	17
1.1.1	<b>Objetivo Geral</b> .....	<b>17</b>
1.1.2	<b>Objetivos Específicos</b> .....	<b>17</b>
1.2	ORGANIZAÇÃO DO TEXTO .....	17
<b>2</b>	<b>ORTHOGONAL FREQUENCY DIVISION MULTIPLEXING (OFDM)</b> .....	<b>18</b>
2.1	ORTOGONALIDADE ENTRE SUBPORTADORAS .....	19
2.2	PREFIXO CÍCLICO.....	19
2.3	TRANSMISSÃO E RECEPÇÃO UTILIZANDO OFDM .....	20
<b>3</b>	<b>PROPAGAÇÃO NO CANAL SEM FIO</b> .....	<b>24</b>
3.1	MODELAGEM DE CANAL .....	25
3.1.1	<b>MODELAGEM DE CANAL EM UM SISTEMA MULTIPORTADORA</b> .....	<b>27</b>
3.2	TAPPED DELAY LINE-A (TDL-A) .....	27
3.3	DESVANECIMENTO RAYLEIGH .....	28
3.4	MULTIPLEXAÇÃO ESPACIAL .....	29
<b>4</b>	<b>REDE NEURAL ARTIFICIAL</b> .....	<b>30</b>
4.1	REDE NEURAL ARTIFICIAL COMPLEXA (RNC).....	32
4.2	REDE NEURAL ARTIFICIAL COMPLEXA COM ATIVAÇÃO SEPARADA (RNAS)	34
<b>5</b>	<b>ESTIMAÇÃO DE CANAL</b> .....	<b>36</b>
5.1	ARRANJO DOS PILOTOS - OFDM .....	36
5.2	TÉCNICAS CLÁSSICAS PARA ESTIMAÇÃO DE CANAL OFDM.....	37
5.2.1	<b>LEAST SQUARES (LS)</b> .....	<b>37</b>
5.2.2	<b>LINEAR MINIMUM MEAN SQUARED ERROR (LMMSE)</b> .....	<b>38</b>
<b>6</b>	<b>ESQUEMA PROPOSTO COM REDES NEURAS ARTIFICIAIS NA ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL</b> .....	<b>40</b>
6.1	PARÂMETROS DE SIMULAÇÃO .....	41
6.2	RESULTADOS DE SIMULAÇÃO .....	43
6.2.1	<b>Etapa de Teste das Redes Neurais</b> .....	<b>49</b>
6.2.2	<b>Impacto do Efeito Doppler</b> .....	<b>50</b>
6.2.3	<b>Robustez à Variação de <math>E_b/N_0</math> em um Modelo Treinado</b> .....	<b>51</b>
6.2.4	<b>Impacto do <i>Delay Spread</i></b> .....	<b>53</b>
6.2.5	<b>Impacto do CP</b> .....	<b>54</b>
<b>7</b>	<b>CONCLUSÃO</b> .....	<b>56</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>58</b>

## 1 INTRODUÇÃO

A quinta geração de internet móvel, conhecida como 5G, não pode ser entendida como um simples avanço em relação a geração anterior, mas sim uma mudança completa em termos gerais de capacidade e potencial. Uma extensa discussão sobre o assunto é feita em (ANDREWS et al., 2014), abordando o aumento de taxas mínimas e máximas, a baixa latência, a densificação de dispositivos transmissores e de células. Além dessas características, novas tecnologias como as *femtocells* (ANDREWS et al., 2012; SOLEIMANI; SABBAGHIAN, 2020) e as ondas milimétricas (BAYKAS et al., 2011; HEATH et al., 2016) viram um aumento exponencial em pesquisas já que possuem potencial para lidarem com as exigências cada vez maiores dos sistemas modernos. Ademais, um fator relevante para a expansão do 5G e das comunicações sem fio é o uso de sistemas de multiplexação por divisão de frequências ortogonais (*Orthogonal Frequency Division Multiplexing*, OFDM) combinados com o uso de várias antenas na transmissão e recepção (*Multiple Input Multiple Output*, MIMO). O OFDM é a evolução da FDM (*Frequency Division Multiplexing*). A sua transmissão serial em portadoras ortogonais em diferentes frequências faz com que a informação possa ser decodificada com menos erros e o símbolo de maior duração faz com que a interferência inter-simbólica (ISI) seja um problema menor. O uso combinado da técnica OFDM e de sistemas MIMO melhorou as comunicações móveis resultando em um salto tecnológico no 5G, mas trouxe a necessidade do desenvolvimento de novas normas, padrões e modelos pelos órgãos responsáveis, como o *3rd Generation Partnership Project* (3GPP) (3GPP, 2024) que é responsável pelo padrão 5G-NR.

Algo que se tornou muito relevante em modelos e no padrão 5G-NR aborda estudos em novos modelos de canal, que definem, para diferentes situações de transmissão e recepção, um perfil de atraso do sinal e seu desvanecimento. Esses modelos são baseados em medições reais a partir dos múltiplos percursos pelos quais o sinal vai chegar ao receptor com diferentes fases, atenuações e atrasos. Nas normas mais recentes, como a (ETSI, 2022), os modelos *tapped delay-line* (TDL) encontrados tem diferentes perfis de atraso e usam a distribuição *Rayleigh* como estatística de desvanecimento. A disponibilidade desse tipo de modelo é relevante para que pesquisadores possam simular sistemas que são factuais com o que acontece em uma transmissão de dados real. Assim, blocos da comunicação sem fio como a estimação de canal e detecção de sinal na recepção de dados podem ser testados e analisados a partir das métricas cabíveis. Estimar esse canal sem fio é entender como esse canal distorce o sinal transmitido a partir do envio de dados, previamente conhecidos no receptor, e é essencial para que se detecte o sinal da melhor forma possível, com menos erros, garantindo uma conexão móvel veloz e confiável.

Nesse contexto, nos últimos anos, as redes neurais artificiais (RNAs) têm sido estudadas e aplicadas como algoritmos de equalização de canal no lugar das técnicas clás-

sicas como filtros adaptativos, *Least Squares* (LS) (BARHUMI; LEUS; MOONEN, 2003) e *Minimum Mean Squared Error* (MMSE) (HSIEH; WEI, 1998). As RNAs vêm sendo utilizadas em inúmeras áreas, dado seu potencial de obter um modelo, por exemplo, uma função, que relaciona a entrada a uma saída desejada sem saber exatamente qual é essa função, mas tendo o comportamento que foi inicialmente buscado. O conceito do neurônio matemático, o menor elemento e mais básico de uma RNA, foi proposto em 1958 por Rosenblatt (ROSENBLATT, 1958), mas grandes avanços recentes foram possibilitados com aumento do poder de processamento dos computadores. Para as telecomunicações, outro avanço muito significativo foi a criação do neurônio complexo (CLARKE, 1990), que facilita e potencializa o trabalho com as mais variadas modulações digitais e sua informação na forma de símbolos, que são números complexos.

A estimação de canal no 5G é analisada em (NGUYEN, 2021) por redes neurais artificiais, convolucionais e recorrentes com a proposta de aprimorar o LS em um sistema MIMO-OFDM com doppler e modelo de canal TDL-C, mostrando que as redes conseguem superar os resultados do MMSE. A estimação de um canal seletivo em frequência é feita em (YANG et al., 2019) a partir de uma RNAR, propondo também uma fase de pré-treino da rede neural que auxilia a inicialização da rede e melhora seus resultados posteriores, que são melhores que as técnicas clássicas. Em (KANG; LIU; YAO, 2022), redes neurais são utilizadas para estimar a melhor posição possível das portadoras piloto e para estimar o canal, conseguindo resultados melhores que as técnicas clássicas usando menos pilotos. A estimação e equalização de canal conjunta é proposta em (YE; LI; JUANG, 2018) para um sistema SISO (*Single Input Single Output*) e OFDM sem prefixo cíclico (CP) por RNARs, mostrando o poder do *machine learning* ao performar melhor que técnicas clássicas e demonstrar robustez em diferentes cenários. (SOUSA et al., 2023) também trabalha esse problema em um sistema OFDM, mas com uma rede neural com função de base radial no domínio complexo, alcançando também resultados melhores que técnicas clássicas a um custo computacional menor que (YE; LI; JUANG, 2018).

A proposta desse trabalho é realizar a estimação e equalização de canal de forma conjunta por diferentes arquiteturas de redes neurais artificiais no domínio real e complexo considerando um sistema sem fio. Nesse sistema considera-se uma transmissão MIMO-OFDM com multiplexação espacial em um canal ruidoso, seletivo em frequência, estático e com múltiplos percursos. Além disso, são considerados cenários adversos onde a rede neural treinada em uma  $E_b/N_0$  é usada em cenários com outras  $E_b/N_0$ , com a presença de efeito Doppler (canal dinâmico), com a ausência do prefixo cíclico OFDM e com um número maior de atrasos no canal.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo Geral

Estudar e analisar a estimação e equalização de canal de forma conjunta a partir de redes neurais artificiais no domínio real e complexo em um sistema de multiplexação espacial MIMO-OFDM.

### 1.1.2 Objetivos Específicos

- Analisar a performance do sistema de multiplexação espacial MIMO-OFDM com ruído *Additive White Gaussian Noise* (AWGN) e o modelo de canal TDL-A com seletividade em frequência.
- Analisar o desempenho de redes neurais artificiais reais e complexas na estimação e equalização de canal conjunta no sistema de multiplexação espacial MIMO-OFDM.
- Analisar a robustez das redes neurais nos seguintes cenários adversos: efeito Doppler (canal dinâmico), símbolo OFDM sem prefixo cíclico, canal com mais atrasos e atuação da rede neural treinada com um sinal de  $E_b/N_0$  baixa em outros cenários.
- Analisar a complexidade computacional das arquiteturas de redes neurais propostas.

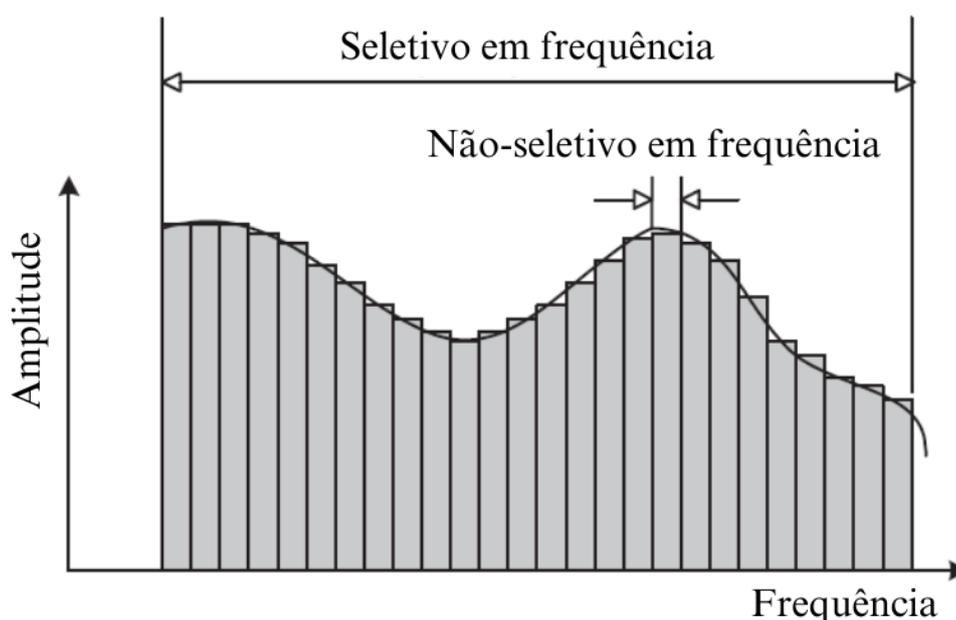
## 1.2 ORGANIZAÇÃO DO TEXTO

Esse trabalho está organizado da seguinte forma: no primeiro capítulo, o problema que será abordado foi introduzido com uma breve contextualização do estado da arte e dos objetivos buscados. No segundo capítulo, o sistema de transmissão é apresentado. No terceiro capítulo, as características de um canal de comunicação sem fio são definidas e o modelo utilizado neste trabalho é mostrado. No quarto capítulo, a matemática das redes neurais artificiais é estudada. A estimação de canal em um sistema OFDM a partir de técnicas clássicas é demonstrada no quinto capítulo, para que no sexto, a abordagem proposta com o uso de RNAs seja feita. O capítulo seis apresenta o sistema proposto e resultados de simulações e discussões para que por fim, no capítulo sete, o trabalho seja concluído.

## 2 ORTHOGONAL FREQUENCY DIVISION MULTIPLEXING (OFDM)

O OFDM é um tipo de transmissão que consiste em um esquema de multiplexação por divisão de frequências (FDM) que usa portadoras ortogonais e foi introduzido por Robert W. Chang da Bell Labs em 1966 (WEINSTEIN, 2009). Nas transmissões de portadora única existe o problema da seletividade em frequência (ver Seção 3) e por isso os sistemas de múltiplas portadoras passaram a ser usados para transmissão de altas taxas de dados. A Figura 1 mostra a resposta em frequência de um sinal de banda larga que é aproximado por múltiplos canais a partir de filtros de banda estreita, onde a não-seletividade em frequência reduz a complexidade dos equalizadores em cada subcanal. Se a ortogonalidade entre os subcanais for mantida, é possível suprimir a *inter-carrier interference* (ICI) (CHO, 2010).

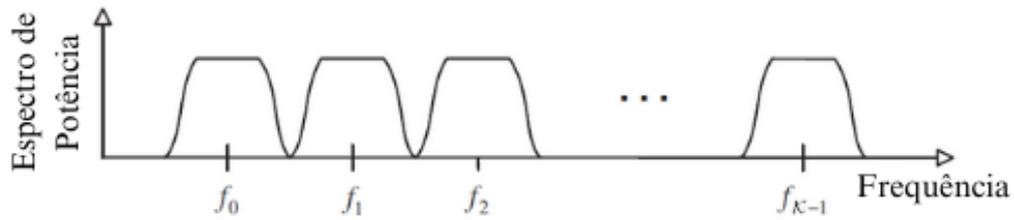
Figura 1 – Seletividade em frequência da transmissão multi-portadora



Fonte: Adaptado de (CHO, 2010)

Na transmissão de múltiplas portadoras, o espectro mostrará a banda larga dividida em subcanais de banda estreita centrados na frequência das subportadoras  $f_k, k = 0, 1, \dots, \mathcal{K} - 1$ , onde  $\mathcal{K}$  é o número subportadoras que ocupam a mesma largura de banda, assim como na Figura 2.

Figura 2 – Espectro de potência da transmissão multi-portadora



Fonte: Adaptado de (CHO, 2010)

## 2.1 ORTOGONALIDADE ENTRE SUBPORTADORAS

Considere sinais complexos limitados no tempo da forma  $\{e^{j2\pi f_k t}\}_{k=0}^{K-1}$  que representam as subportadoras no símbolo OFDM, onde  $f_k = k/T_s$  e  $T_s$  é a duração do símbolo. Estes sinais serão ortogonais se a integral do produto entre eles no período fundamental for zero, ou seja,

$$\begin{aligned} \frac{1}{T_s} \int_0^{T_s} e^{j2\pi f_k t} e^{-j2\pi f_i t} dt &= \frac{1}{T_s} \int_0^{T_s} e^{j2\pi \frac{k}{T_s} t} e^{-j2\pi \frac{i}{T_s} t} dt \\ &= \frac{1}{T_s} \int_0^{T_s} e^{j2\pi \frac{k-i}{T_s} t} dt \\ &= \begin{cases} 1, & k = i \\ 0, & k \neq i \end{cases} \end{aligned} \quad (2.1)$$

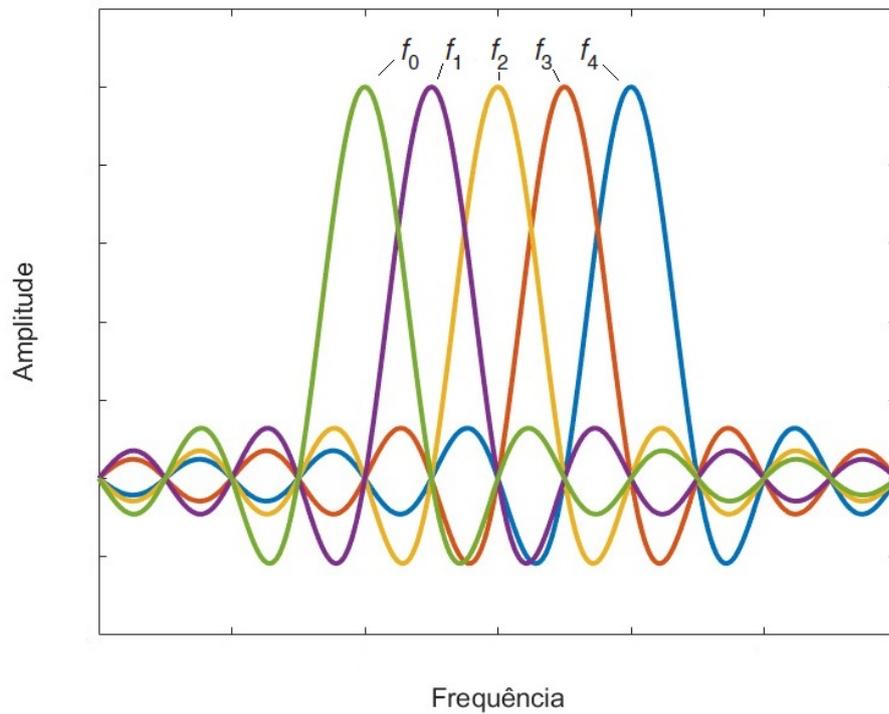
onde  $0 \leq t \leq T_s$  e  $i \in \mathbb{Z}$ .

A ortogonalidade entre as subportadoras é mostrada na Figura 3, sendo esta necessária para evitar a ICI (conforme Equação 2.1) no símbolo OFDM (CHO, 2010). Cada subportadora está centrada em sua frequência  $f_k$ , garantindo a ortogonalidade.

## 2.2 PREFIXO CÍCLICO

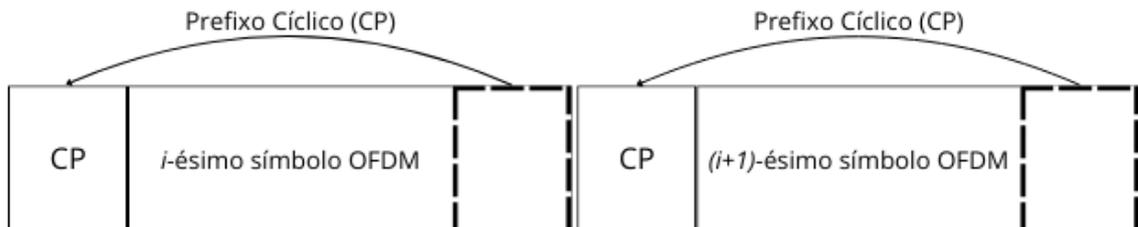
Nomeado de prefixo cíclico, esse elemento da transmissão OFDM consiste na cópia dos  $N_{cp}$  últimas amostras do símbolo OFDM para que sejam anexados no início do mesmo. O CP tem por objetivo atuar como um intervalo de guarda, contornando o problema da ISI de forma que seu tamanho é pensado para cobrir os impulsos do canal que são causados pelos ecos dos multipercursos. O uso do CP vai aumentar o tamanho do símbolo OFDM com informação "inútil", mas é essencial para lidar com a interferência entre os símbolos (CHO, 2010). A Figura 4 ilustra a formação do símbolo OFDM com a inserção do CP.

Figura 3 – Ortogonalidade das subportadoras no domínio da frequência



Fonte: O Autor

Figura 4 – Ilustração do prefixo cíclico do símbolo OFDM



Fonte: O Autor

### 2.3 TRANSMISSÃO E RECEPÇÃO UTILIZANDO OFDM

O sistema OFDM transmite símbolos fonte  $q_k = 0, \dots, \mathcal{K} - 1$  paralelamente em  $\mathcal{K}$  subportadoras. A duração de um símbolo fonte é dada por  $T_d$  e após a paralelização e

conversão para a duração de um símbolo OFDM, esse tempo será:

$$T_s = \mathcal{K}T_d. \quad (2.2)$$

A partir de  $T_s$ , usa-se o princípio OFDM para modular as  $\mathcal{K}$  subportadoras com um espaçamento  $F_{cs}$  de

$$F_{cs} = \frac{1}{T_s} \quad (2.3)$$

para manter a ortogonalidade entre os sinais nas  $\mathcal{K}$  subportadoras. Aos  $\mathbf{q}_k$  símbolos fonte modulados se dá o nome de símbolo OFDM. Considerando um pulso retangular, o envelope complexo do símbolo OFDM será da forma

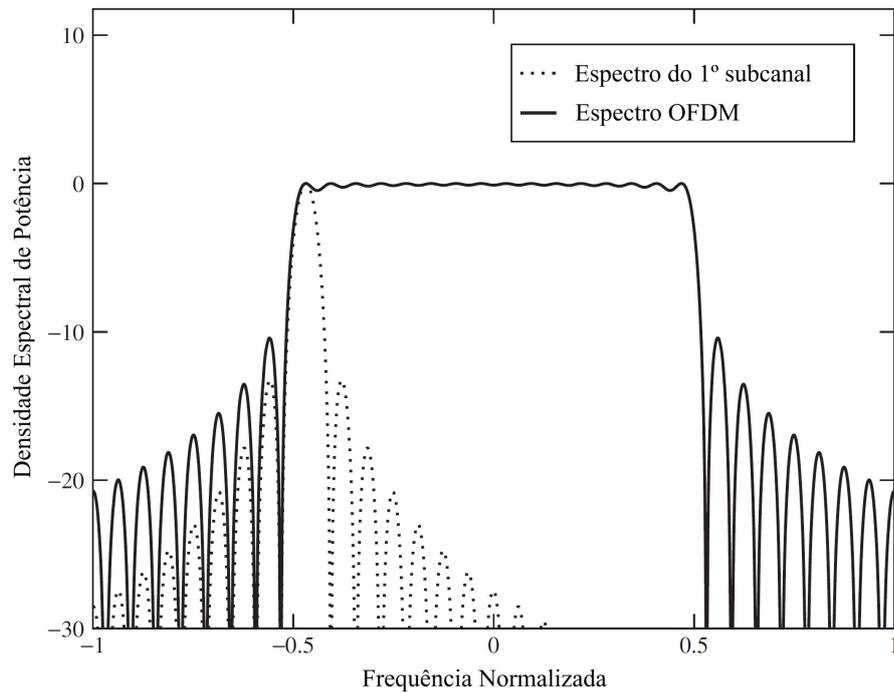
$$env(t) = \frac{1}{\mathcal{K}} \sum_{k=0}^{\mathcal{K}-1} \mathbf{q}_k e^{j2\pi f_k t}, \quad 0 \leq t < T_s, \quad (2.4)$$

onde as  $\mathcal{K}$  frequências das subportadoras estão localizadas em

$$f_k = \frac{k}{T_s}, \quad k = 0, \dots, \mathcal{K} - 1 \quad (2.5)$$

O símbolo OFDM pode ser visualizado a partir da densidade espectral de potência normalizada como mostra a Figura 5. Nela, os símbolos transmitidos têm a mesma potência e enquanto a curva pontilhada mostra o espectro da primeira subportadora, a curva contínua mostra o resultado total considerando todas subportadoras. É possível notar que para um grande número de subportadoras, o espectro tende a se tornar plano na faixa de frequência que engloba os  $\mathcal{K}$  subcanais.

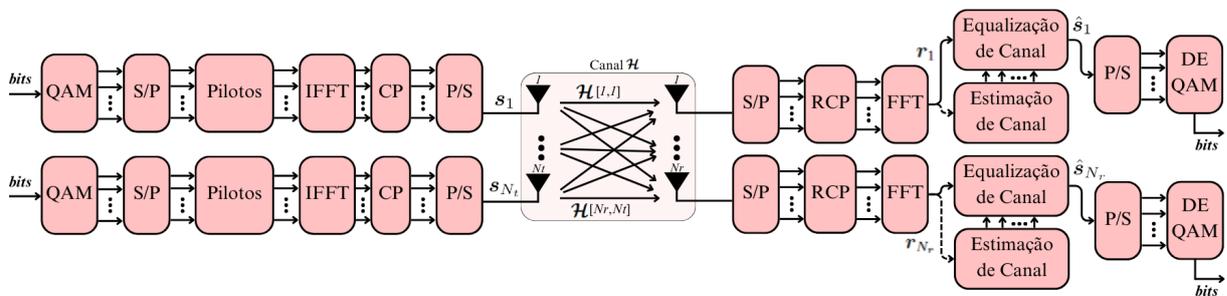
Figura 5 – Densidade Espectral de Potência Normalizada do Símbolo OFDM



Fonte: Adaptado de (FAZEL; KAISER, 2008)

A Figura 6 mostra o esquema de transmissão e recepção MIMO-OFDM considerado nesse trabalho. Inicialmente, na parte de transmissão (Tx),  $N_t$  seqüências distintas de bits são mapeados em símbolos QAM que serão convertidos em  $K$  subportadoras paralelas pelo bloco S/P. Em seguida, as subportadoras piloto são inseridas entre as subportadoras com informação útil de acordo com o esquema de estimação de canal usado na recepção (Rx). O bloco IFFT então leva o sinal do domínio da frequência para o domínio do tempo, onde um prefixo cíclico (CP) de tamanho  $N_{cp}$  é adicionado no início de cada IFFT para que a *Inter-Symbol Interference* (ISI) seja amenizada. Por fim, cada sinal é serializado e transmitido por cada antenna.

Figura 6 – Esquemático do Sistema OFDM



Fonte: Autor

Considerando um canal multipercurso composto de  $N_d$  atrasos, o sinal recebido em

banda-base é

$$\mathbf{r}[n] = \sum_{\tau=0}^{N_d-1} \mathcal{H}_{\tau+1}[n] \mathbf{s}[n - \tau] + \mathbf{a}[n] \quad (2.6)$$

onde  $n$  é o índice discreto de tempo,  $\mathcal{H}_{\tau+1}$  é a matriz do canal no atraso  $\tau$ ,  $\mathbf{s}[n]$  é o vetor com a informação transmitida e  $\mathbf{a} \sim \mathcal{CN}(0, \sigma_w^2) \in \mathbb{C}$  é o ruído Gaussiano branco aditivo (do inglês *Additive White Gaussian Noise* - AWGN) no receptor, com média zero e variância  $\sigma_a^2$ .

Após o envio de cada sinal  $\mathbf{s}[n]$  pelo canal sem fio  $\mathcal{H}$ , cada sinal recebido  $\mathbf{r}[n]$  é paralelizado e o CP é removido para que então seja feita a conversão para o domínio da frequência. O resultado disso alimenta o bloco de estimação de canal que provê a informação usada na equalização do canal, processo que retira o efeito do canal de cada sinal  $\mathbf{r}[n]$ , gerando cada sinal  $\hat{\mathbf{s}}[n]$ . Por fim, cada sinal é serializado e os símbolos são convertidos em bits pelo bloco DEQAM, formando o vetor de bits recebidos.

### 3 PROPAGAÇÃO NO CANAL SEM FIO

Muitas comunicações sem fio terrestres ocorrem em meios compostos pelos mais variados tipos de obstáculos, como construções, terrenos elevados, automóveis e vegetação em geral. Dessa forma, o modo de propagação em espaço livre, caracterizado pelo nível de potência recebido que diminui com o quadrado da distância do transmissor, não reflete as características da maior parte dos ambientes. Na maioria dos cenários de comunicação não existe uma linha de visada entre transmissor e receptor, de modo que o espalhamento a partir da reflexão e difração das ondas gerando múltiplos percursos é algo inerente na comunicação entre os terminais (HAYKIN; MOHER, 2009).

Os principais mecanismos envolvidos na propagação pelo canal sem fio são:

- Perdas por Percurso: relação que define a perda da potência média do canal ao longo do percurso entre transmissor e receptor. Em casos com linha de visada, usa-se a equação de Friss conhecida como desvanecimento em larga escala. Nos canais sem fio utilizados atualmente muitas vezes a linha de visada está bloqueada, e então outros fatores deverão ser considerados (CHO, 2010).
- Multipercurso: consequência da interação da onda com obstáculos (reflexões, difrações e dispersões). Faz com que na recepção, cheguem diversos sinais com diferentes atenuações, fases e atrasos de forma que sua superposição altere o sinal recebido (JUNIOR, 2017).
- Efeito Doppler: fenômeno físico que causa variação temporal nas amplitudes e fases dos sinais devido ao movimento de objetos ou do próprio receptor (FAZEL; KAISER, 2008).
- Seletividade em Frequência: quando os atrasos dos multipercursos têm um espalhamento grande, o canal é chamado de seletivo em frequência e sabe-se então que haverá problema de ISI. Com o efeito doppler essa seletividade piora, pois o canal se torna variante no tempo (GRAMI, 2016).
- Sombreamento: causado pela obstrução das ondas por objetos de natureza variada, resultando em uma atenuação no sinal. O desvanecimento lento é o nome dado para a variação da intensidade do sinal em função do sombreamento (JUNIOR, 2017).

O entendimento do canal sem fio está ligado ao conhecimento das características de sua variação no tempo e na frequência. Essas variações podem ser dadas pela perda de potência, pelo percurso, pelo sombreamento por grandes obstáculos (independentes da frequência) ou pelas interferências dos múltiplos caminhos do sinal entre o transmissor e o receptor. (TSE; VISWANATH, 2005).

### 3.1 MODELAGEM DE CANAL

Modelar o canal sem fio pode se tornar uma tarefa muito complexa, especialmente quando a abordagem é por meio do traçado de raios (do inglês, *ray tracing*). Estes representam a onda, que no caso de reflexões e difrações múltiplas tornam os cálculos complicados. Modelos estatísticos são mais usados devido a aproximação empírica baseada em medidas realizadas em ambientes genéricos, como urbano e rural. Em um modelo de canal, teremos então uma estatística, uma estimativa de perdas médias e locais a partir da soma das interferências construtivas e destrutivas de cada percurso dos sinais e suas rotações de fase (HAYKIN; MOHER, 2009).

O canal sem fio pode ser caracterizado pela resposta ao impulso do canal  $\mathbf{h}(\tau, t)$  considerando o tempo  $t$  e um atraso  $\tau$  ou pela resposta em frequência do canal variante no tempo  $\mathcal{H}(f, t)$ , que é a transformada de Fourier (*Fourier Transform, FT*) de  $\mathbf{h}(\tau, t)$ . A resposta ao impulso do canal representa a resposta do canal no tempo  $t$  devido a um impulso aplicado no tempo  $t - \tau$  (FAZEL; KAISER, 2008). Considerando que o canal é um processo aleatório estacionário, ou seja, tenha uma estatística de desvanecimento que se mantém constante em curtos períodos de tempo ou em pequenas distâncias nos ambientes com multipercursos, a resposta ao impulso é composta por inúmeros impulsos espalhados que foram recebidos em  $N_p$  caminhos diferentes da seguinte forma:

$$\mathbf{h}(\tau, t) = \sum_{p=0}^{N_p-1} (a_p e^{j(2\pi f_{D,p}t + \varphi_p)} \delta(\tau - \tau_p)), \quad (3.1)$$

onde

$$\delta(\tau - \tau_p) = \begin{cases} 1, & \text{se } \tau = \tau_p \\ 0, & \text{se } \tau \neq \tau_p \end{cases} \quad (3.2)$$

sendo  $a_p$ ,  $f_{D,p}$ ,  $\varphi_p$  e  $\tau_p$ , a amplitude, a frequência Doppler, a fase e o atraso de propagação relacionado ao caminho  $p$ , respectivamente. A partir disso, a resposta em frequência do canal é

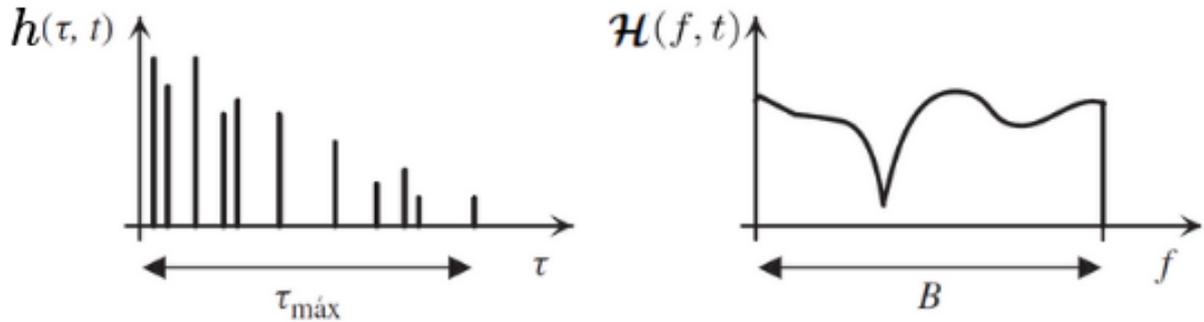
$$\mathcal{H}(f, t) = \sum_{p=0}^{N_p-1} (a_p e^{j(2\pi f_{D,p}t - f\tau_p) + \varphi_p}). \quad (3.3)$$

A resposta ao impulso do canal, assim como sua resposta em frequência correspondente na banda  $B$  é ilustrada na Figura 7.

Os atrasos são medidos relativos ao primeiro caminho detectado no receptor, onde a frequência Doppler é

$$f_{D,p} = \frac{v f_c \cos(\alpha_p)}{c} \quad (3.4)$$

Figura 7 – Resposta ao impulso do canal em um instante de tempo e resposta em frequência com desvanecimento seletivo em frequência



Fonte: Adaptado de (FAZEL; KAISER, 2008)

onde  $v$  é a velocidade do terminal,  $c$  é a velocidade da luz,  $f_c$  é a frequência da portadora e  $\alpha_p$  é o ângulo de incidência de uma onda em um percurso  $p$ .

O espectro da densidade de potência  $\rho(\tau)$  que caracteriza a seletividade em frequência do canal sem fio dá a potência média de saída do canal como função do atraso  $\tau$ . O atraso médio  $\bar{\tau}$ , a raiz quadrada média (*Root Mean Square* - RMS) da propagação do atraso  $\tau_{RMS}$  e o atraso máximo  $\tau_{max}$  são parâmetros da densidade espectral de potência do atraso. O atraso médio é dado por

$$\bar{\tau} = \frac{\sum_{p=0}^{N_p-1} \tau_p \Omega_p}{\sum_{p=0}^{N_p-1} \Omega_p}, \quad (3.5)$$

onde  $\Omega_p = |a_p|^2$  é a potência do caminho  $p$ . O valor RMS do atraso de propagação, por sua vez, é

$$\tau_{RMS} = \sqrt{\frac{\sum_{p=0}^{N_p-1} \tau_p^2 \Omega_p}{\sum_{p=0}^{N_p-1} \Omega_p} - \bar{\tau}^2}. \quad (3.6)$$

De forma similar, o espectro da densidade de potência do efeito Doppler caracteriza a variância temporal do canal sem fio (quando um receptor está se movimentando em relação ao transmissor) e dá a potência média da saída do canal como função da frequência Doppler  $f_D$  (FAZEL; KAISER, 2008). As propriedades da frequência dispersiva dos canais dos multipercursos são geralmente quantificados pela ocorrência máxima do Doppler  $f_{D_{max}}$  e do espalhamento Doppler  $f_{D_s}$ . O espalhamento Doppler é, na verdade, a largura de banda (do inglês, *BandWidth* - BW) do espectro da densidade de potência do Doppler e pode ter os valores

$$f_{D_s} \leq 2|f_{D_{max}}|. \quad (3.7)$$

### 3.1.1 MODELAGEM DE CANAL EM UM SISTEMA MULTIPORTADORA

Sistemas multiportadoras podem ser simulados de forma mais eficiente no domínio da frequência. Considerando um cenário ideal onde não há (ISI), *Intercarrier Interference* (ICI), seletividade em frequência para cada subportadora e variância temporal do canal durante um símbolo OFDM (ver Seção 2.2) (FAZEL; KAISER, 2008), a função de transferência discreta do canal será

$$\begin{aligned}
 \mathcal{H}_{k,i} &= \mathcal{H}(kF_{cs}, iT'_{cs}) \\
 &= \sum_{p=0}^{N_P-1} a_p e^{j(2\pi(f_{D,p}iT'_{cs} - kF_{cs}\tau_p) + \varphi_p)} \\
 &= a_{k,i} e^{j\varphi_{k,i}}
 \end{aligned} \tag{3.8}$$

onde a função de transferência contínua  $\mathcal{H}(f, t)$  é amostrada temporalmente na taxa  $1/T'_s$  e na frequência no espaçamento entre subportadoras de  $F_{cs}$ . A duração de símbolo  $T'_s$  é a duração total do símbolo OFDM com o prefixo cíclico. Finalmente, o símbolo transmitido no subcanal  $k$  do símbolo OFDM  $i$  é multiplicado pela amplitude resultante do desvanecimento  $a_{k,i}$  e rotacionado por uma fase  $\varphi_{k,i}$ .

### 3.2 TAPPED DELAY LINE-A (TDL-A)

Para que seja possível simular cenários práticos, uma alternativa plausível é o uso das normas para canais físicos e modulação no 5G, que são dadas pelo 3GPP. Nessas normas, encontram-se os perfis de atraso baseados em TDL, que descrevem o número de atrasos, o tempo desses atrasos e a atenuação de cada um deles. Para computar cada amostra do canal multipercurso, é usado um modelo de canal que foi obtido experimentalmente a partir do envio de um símbolo e da análise dos seus ecos que chegam na recepção. De acordo com (ETSI, 2020), tem-se por exemplo o modelo TDLA100, com o perfil de atraso e a distribuição Rayleigh. Além disso, nesse modelo o canal é seletivo em frequência. A Tabela 1 mostra as características do modelo TDL-A.

Tabela 1 – Modelo de Canal TDL-A

Atraso	Atraso Normalizado	Potência em dB	Desvanecimento
1	0.0000	-13.4	<i>Rayleigh</i>
2	0.3819	0	<i>Rayleigh</i>
3	0.4025	-2.2	<i>Rayleigh</i>
4	0.5868	-4	<i>Rayleigh</i>
5	0.4610	-6	<i>Rayleigh</i>
6	0.5375	-8.2	<i>Rayleigh</i>
7	0.6708	-9.9	<i>Rayleigh</i>
8	0.5750	-10.5	<i>Rayleigh</i>
9	0.7618	-7.5	<i>Rayleigh</i>
10	1.5375	-15.9	<i>Rayleigh</i>

Fonte: Adaptado de (ETSI, 2020)

### 3.3 DESVANECIMENTO RAYLEIGH

O modo mais simples de modelar os coeficientes de um canal é assumir que existem muitos percursos refletidos e espalhados estatisticamente independentes com amplitudes aleatórias considerando a janela de atraso de um coeficiente (TSE; VISWANATH, 2005). Além disso, é razoável assumir que a fase de cada percurso é distribuída uniformemente entre o intervalo de 0 a  $2\pi$  e as fases entre diferentes caminhos são independentes. A contribuição de cada percurso, segundo (TSE; VISWANATH, 2005), pode ser modelada por uma variável aleatória complexa simétrica circularmente e isso implica que cada coeficiente é a soma de muitas dessas variáveis. A partir disso, baseando-se no Teorema do Limite Central, pode-se modelar um coeficiente por uma variável Gaussiana aleatória de média nula.

Esse modelo é chamado de desvanecimento *Rayleigh* e é razoável para ambientes com muitos refletores pequenos, sendo usado principalmente pela sua simplicidade em situações típicas de transmissão sem fio. Apesar do modelo ser conhecido universalmente como *Rayleigh*, os coeficientes do canal são modelados como variáveis aleatórias Gaussianas complexas simétricas circularmente.

### 3.4 MULTIPLEXAÇÃO ESPACIAL

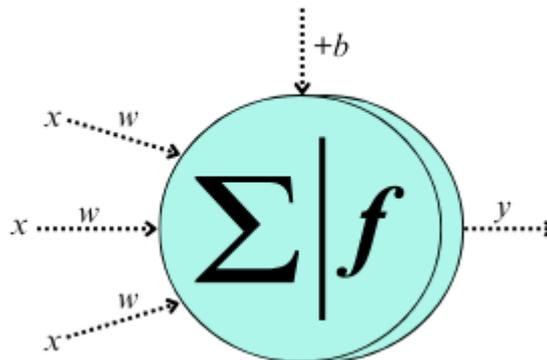
A demanda crescente de altas taxas de transmissão de dados em sistemas de comunicação sem fio encontra uma barreira devido aos limites do espectro de frequência, já que a largura de banda é um recurso limitado e nem sempre é possível alocar mais dela (ELSHOKRY, 2010). A partir disso, os esforços de desenvolvimento se voltaram para o aumento da capacidade de transmissão sem a necessidade de mais alocação de largura de banda nos sistemas MIMO, concluindo que a multiplexação espacial oferece um aumento linear na taxa de dados dentro dos recursos espectrais disponíveis (ELSHOKRY, 2010; WOLNIANSKY, 1998).

A multiplexação espacial consiste na transmissão de  $N_t$  múltiplas sequências independentes de símbolos IQ no mesmo instante de tempo usando a mesma frequência, onde cada sequência de símbolos é submetida à mesma qualidade de canal que seria vista em um sistema SISO. Essas sequências poderão ser separadas de forma satisfatória se o ambiente de transmissão tiver um espalhamento rico (REDDY, 2010). Enquanto os sistemas MIMO que usam técnicas de diversidade alcançam maiores SNR, os que usam multiplexação espacial provêm maior capacidade de canal sem a necessidade de mais recursos espectrais (ELSHOKRY, 2010).

## 4 REDE NEURAL ARTIFICIAL

Proposto pela primeira vez por (ROSENBLATT, 1958) o perceptron ou neurônio matemático é a estrutura que tenta emular o comportamento de um neurônio humano a partir de uma transformação não-linear.

Figura 8 – Neurônio Artificial (Perceptron).



Fonte: O Autor

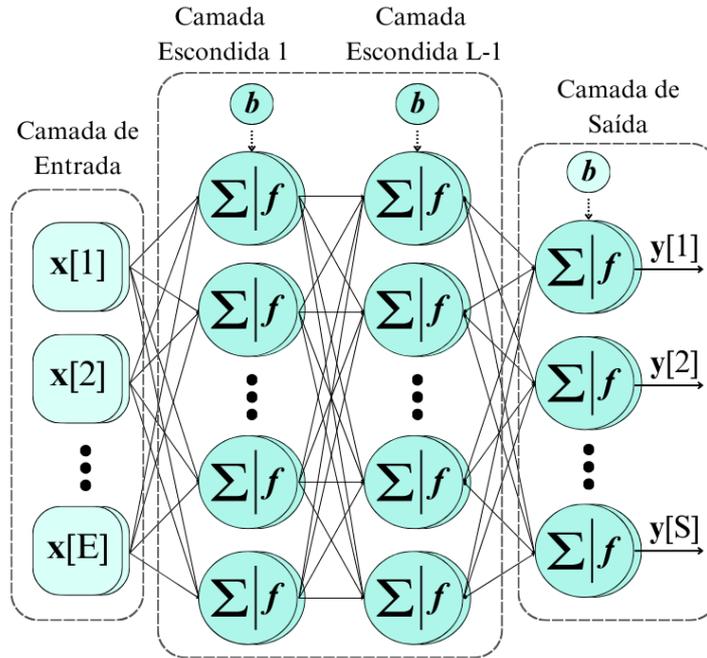
Na Figura 8, o neurônio e seus elementos são mostrados. Esse funciona como uma função, recebendo entradas e tendo como saída a transformação não-linear dessas entradas. A equação generalizada que o define é

$$y = \sum f(\mathbf{w}^T \mathbf{x} + b), \quad (4.1)$$

onde  $y$  é a saída do neurônio,  $\mathbf{w}$  é um vetor contendo o peso que pondera cada uma das conexões (sinapses),  $\mathbf{x}$  é vetor de entradas do neurônio,  $b$  é um valor que tendencia a resposta, denominado *bias*, e  $f$  é uma função de ativação responsável por adicionar à não-linearidade a essa transformação (HAYKIN, 1999). Nessa equação há dois parâmetros modificáveis responsáveis pela transformação das entradas: os pesos e o *bias*. Dessa forma, se há um objetivo no uso do neurônio como função, esses parâmetros podem ser atualizados para melhor responder ao objetivo. Isso é feito a partir da definição de uma resposta desejada para uma entrada específica tornando possível o cálculo da função custo (estimativa de erro). Considera-se que para o  $y$  da Equação 4.1 há uma saída desejada  $d$  a partir de uma entrada  $x$ , e a diferença entre  $y$  e  $d$  é dada por

$$e = d - y. \quad (4.2)$$

O avanço das pesquisas permitiu que uma estrutura mais complexa fosse desenvolvida a partir do uso de vários neurônios totalmente conectados em uma arquitetura de vá-

Figura 9 – Rede Neural Artificial (*Multi-Layer Perceptron*)

Fonte: O Autor

rias camadas, além de um algoritmo de aprendizado que pudesse lidar com isso. A Figura 9 mostra essa estrutura, chamada de Rede Neural Artificial Real (RNAR). Nela, a camada de entrada, definida por  $l = 0$  é composta pelo vetor de entradas  $\mathbf{x} \in \mathbb{R}^E$ , sendo  $E$  o número de entradas. Depois, vêm as camadas escondidas definidas por  $l \in [1, 2, \dots, L-1]$  e então a camada de saída definida por  $l = L$ , de forma que a RNAR tenha, considerando a camada de entrada,  $L + 1$  camadas. De forma generalizada, a camada escondida  $l$  possui  $I$  neurônios, uma matriz de pesos sinápticos  $\mathbf{W} \in \mathbb{R}^{I^{[l]} \times I^{[l-1]}}$ , um vetor de *bias*  $\mathbf{b} \in \mathbb{R}^{I^{[l]}}$  e uma função de ativação  $f^{[l]}(\cdot)$ .

Na arquitetura da Figura 9, a RNAR será alimentada com dados de entrada que serão propagados pelas sinapses até os neurônios das camadas escondidas e por fim até a camada de saída, processo nomeado de *forward propagation*. A equação que define a saída de cada camada da RNAR nesse processo é

$$\mathbf{y}[n]^{[l]} = \begin{cases} \mathbf{x}, & l = 0 \\ f^{[l]}(\mathbf{v}[n]^{[l]}), & 1 \leq l \leq L, \end{cases} \quad (4.3)$$

onde  $n$  é o índice temporal discreto e  $\mathbf{v}^{[l]}$  é

$$\mathbf{v}[n]^{[l]} = \mathbf{W}[n]^{[l]} \mathbf{y}[n]^{[l-1]} + \mathbf{b}[n]^{[l]}. \quad (4.4)$$

Depois dos dados passarem pela RNAR e resultarem na saída da camada  $L$ , utiliza-

se a função de custo *Mean Squared Error* (MSE) para calcular o erro entre a saída obtida e a saída desejada, da forma

$$J[n] = E\{\|e[n]\|^2\} = E\{\|\mathbf{d}[n] - \mathbf{y}[n]\|^2\} = \frac{1}{2}\|\mathbf{d}[n] - \mathbf{y}[n]\|^2. \quad (4.5)$$

Assim como no perceptron, na RNAR podemos atualizar os parâmetros de pesos e *bias* pelo algoritmo de *backpropagation*. O *backpropagation* é uma técnica que busca minimizar a função de custo  $J$  usando o gradiente descendente e faz o caminho reverso do *forward propagation* a partir da regra Delta (WIDROW B.; HOFF, 1960), que adaptada para a RNAR, é dada por

$$w_{s,m}^{[l]}[n+1] = w_{s,m}^{[l]}[n] - \eta_w (\nabla_{w_{s,m}^{[l]}} J[n]), \quad (4.6)$$

$$b_s^{[l]}[n+1] = b_s^{[l]}[n] - \eta_b (\nabla_{b_s^{[l]}} J[n]) \quad (4.7)$$

onde  $w_{s,m}^{[l]}$  é o peso sináptico que liga o  $m$ -ésimo neurônio da camada  $l-1$  ao  $s$ -ésimo neurônio da camada  $l$ ,  $b_s^{[l]}$  é o *bias* do  $s$ -ésimo neurônio da camada  $l$  e  $\eta_w$  e  $\eta_b$  são as taxas de aprendizado dos pesos e *bias*.

Considerando uma RNAR com  $E$  entradas,  $L$  camadas escondidas e  $S$  saídas, onde cada camada possui  $I^{[l]}$  neurônios, a Tabela 2 mostra a complexidade computacional da RNAR, onde  $f(\cdot)$  e  $f'(\cdot)$  são o número de funções de ativação e suas derivadas, respectivamente.

Tabela 2 – Complexidade computacional da RNAR

Fase	Adições	Multiplicações	$f(\cdot)$	$f'(\cdot)$
Treinamento	$\sum_{l=1}^{L-1} I^{[l]}(2I^{[l-1]} + I^{[l+1]} + 2) + I^{[L]}(2I^{[L-1]} + 1)$	$\sum_{l=1}^{L-1} I^{[l]}(2I^{[l-1]} + I^{[l+1]} + 3) + I^{[L]}(2I^{[L-1]} + 3)$	$\sum_{l=1}^L I^{[l]}$	$\sum_{l=1}^L I^{[l]}$
Validação	$\sum_{l=1}^L I^{[l]}I^{[l-1]}$	$\sum_{l=1}^L I^{[l]}I^{[l-1]}$	$\sum_{l=1}^L I^{[l]}$	—

Fonte: (MAYER, 2022)

#### 4.1 REDE NEURAL ARTIFICIAL COMPLEXA (RNC)

O principal desafio em relação ao perceptron complexo é a falta de funções complexas não-lineares analíticas e limitadas no plano complexo  $\mathbb{C}$ . De acordo com o teorema de Liouville, uma função inteira e limitada deve ser constante em  $\mathbb{C}$ , onde uma função inteira é definida como analítica (diferenciável em todo ponto do plano complexo). O que

acontece é que não é possível encontrar uma função complexa não-linear analítica que é totalmente limitada em  $\mathbb{C}$  tornando difícil o processo de encontrar uma função de ativação para as RNCs (KIM; ADALI, 2002; KIM; ADALI, 2003). A seleção de funções de ativação que cumprem os requisitos são as funções de ativação elementares transcendentais (MAYER, 2022), que são as deriváveis de  $e^z$ , possuindo mapeamento não-linear de fase. Algumas comuns são  $\tan(z)$ ,  $\sin(z)$ ,  $\tanh(z)$ ,  $\arcsin(z)$ , por exemplo.

A estrutura de uma RNC é a mesma de uma RNAR, exceto pelo fato de que ela trabalha no domínio complexo. As entradas, pesos sinápticos e bias pertencerão então ao conjunto dos números complexos. Além disso, há também a questão da função de ativação que foi discutida anteriormente. Dessa forma, as equações que definem o vetor de saída de uma  $l$ -ésima camada da RNC são:

$$\mathbf{y}^{[l]}[n] = \Re(\mathbf{y}^{[l]}[n]) + j\Im(\mathbf{y}^{[l]}[n]) = \begin{cases} \mathbf{x}[n], & l = 0 \\ f^l(\mathbf{v}^{[l]}[n]), & 1 \leq l \leq L, \end{cases} \quad (4.8)$$

onde  $\Re$  é a parte real de um número complexo,  $\Im$  a parte imaginária,  $l$  é a camada da rede neural,  $\mathbf{x} \in \mathbb{C}^E$  é o vetor de entradas,  $f$  é a função de ativação e  $\mathbf{v}$  é:

$$\mathbf{v}^{[l]}[n] = \Re(\mathbf{v}^{[l]}[n]) + j\Im(\mathbf{v}^{[l]}[n]) = \mathbf{W}^{[l]}[n]\mathbf{y}^{[l-1]}[n] + \mathbf{b}^{[l]}[n], \quad (4.9)$$

onde  $\mathbf{W}^{[l]} \in \mathbb{C}^{I^{[l]} \times I^{[l-1]}}$  é a matriz de pesos sinápticos que pondera as conexões dos  $I$  neurônios da camada  $l$  com a camada  $l-1$  e  $\mathbf{b}^{[l]} \in \mathbb{C}^{I^{[l]}}$  é o vetor de bias da camada  $l$ .

Novamente, o *backpropagation* usa a regra delta para  $w_{s,i}^{[l]}$  e  $b_s^{[l]}$ :

$$w_{s,i}^{[l]}[n+1] = w_{s,i}^{[l]}[n] - \eta(\nabla_{w_{s,i}^{[l]}} J[n]), \quad (4.10)$$

$$b_s^{[l]}[n+1] = b_s^{[l]}[n] - \eta(\nabla_{b_s^{[l]}} J[n]), \quad (4.11)$$

onde  $w_{s,i}^{[l]}$  é o peso sináptico que liga o  $i$ -ésimo neurônio da camada  $l-1$  ao  $s$ -ésimo neurônio da camada  $l$  e  $b_s^{[l]}$  é o bias do  $s$ -ésimo neurônio da camada  $l$ . As provas e teoremas das equações acima podem ser encontradas nos trabalhos de (KIM; ADALI, 2002) e (MAYER, 2022).

Considerando uma RNC com  $E$  entradas,  $L$  camadas escondidas e  $S$  saídas, onde cada camada possui  $I^{[l]}$  neurônios, a Tabela 3 mostra a complexidade computacional da RNC, onde  $f(\cdot)$  e  $f'(\cdot)$  são o número de funções de ativação e suas derivadas, respectivamente.

Tabela 3 – Complexidade computacional da RNC

Fase	Adições	Multiplicações	$f(\cdot)$	$f'(\cdot)$
Treinamento	$\sum_{l=1}^{L-1} (8I^{l-1} + 4I^{l+1} + 2) + I^{[L]}(8I^{L-1} + 4)$	$\sum_{l=1}^{L-1} (8I^{l-1} + 4I^{l+1} + 8) + 8I^{[L]}(I^{L-1} + 1)$	$\sum_{l=1}^L I^{[l]}$	$\sum_{l=1}^L I^{[l]}$
Validação	$4 \sum_{l=1}^L I^{[l]} I^{l-1}$	$4 \sum_{l=1}^L I^{[l]} I^{l-1}$	$\sum_{l=1}^L I^{[l]}$	—

Fonte: (MAYER, 2022)

#### 4.2 REDE NEURAL ARTIFICIAL COMPLEXA COM ATIVAÇÃO SEPARADA (RNAS)

A RNAS é derivada da RNC com a diferença que a função de ativação será aplicada separadamente na parte real e na parte imaginária, de forma que será possível usar uma função de ativação real não-linear (MAYER, 2022). A motivação dessa abordagem foi contornar problemas de instabilidade da RNC, já que a mesma possui funções de ativação que não são totalmente limitadas no plano complexo e podem causar instabilidade no sistema.

A arquitetura da RNAS é similar a RNC, com a única diferença na função de ativação separada, como mostra a Equação 4.12.

$$\mathbf{y}^{[l]}[n] = \Re(\mathbf{y}^{[l]}[n]) + j\Im(\mathbf{y}^{[l]}[n]) = \begin{cases} \mathbf{x}[n], & l = 0 \\ f^{[l]}[\Re(\mathbf{v}^{[l]}[n])] + j f^{[l]}[\Im(\mathbf{v}^{[l]}[n])], & 1 \leq l \leq L \end{cases} \quad (4.12)$$

O *backpropagation* da RNAS também segue a regra Delta e sendo detalhada em (KIM; ADALI, 2002) e (MAYER, 2022). Na Tabela 4, a complexidade computacional é demonstrada sendo similar à RNC.

Tabela 4 – Complexidade computacional da RNAS

Fase	Adições	Multiplicações	$f(\cdot)$	$f'(\cdot)$
Treinamento	$\sum_{l=1}^{L-1} (8I^{l-1} + 4I^{l+1}) + I^L(8I^{L-1} + 2)$	$\sum_{l=1}^{L-1} (8I^{l-1} + 4I^{l+1} + 8) + I^L(8I^{L-1} + 6)$	$2 \sum_{l=1}^L I^l$	$2 \sum_{l=1}^L I^l$
Validação	$4 \sum_{l=1}^L I^l I^{l-1}$	$4 \sum_{l=1}^L I^l I^{l-1}$	$2 \sum_{l=1}^L I^l$	—

Fonte: (MAYER, 2022)

Apesar de contornarem o problema da instabilidade, a RNAS tem dificuldade na

representação de fase, dada o cálculo independente da função de ativação na parte real e imaginária (SAVITHA; SURESH; SUNDARARAJAN, 2012).



O arranjo *block-type*, como mostra a Figura 10(a) consiste em preencher um símbolo inteiro com pilotos, ou seja, utilizando todas subportadoras daquele símbolo. A estimativa baseada nesses pilotos será usada para os próximos símbolos até que um novo símbolo OFDM de pilotos será inserido e para que isso seja possível, o tempo de coerência (intervalo no qual é considerado que o canal não muda) deve abranger as portadoras de dados até a próxima inserção de pilotos. Esse tipo de arranjo é ideal para canais de desvanecimento lento.

O arranjo *comb-type* da Figura 10(b), por outro lado, insere periodicamente um piloto em certas frequências. Dessa forma, um mesmo símbolo OFDM será composto por subportadoras de dados e subportadoras piloto, fazendo com que seja necessário o uso de interpolação para estimar o canal entre as subportadoras de pilotos, ou seja, nas subportadoras de dados. Dado que há pilotos em todos símbolos, esse tipo de arranjo é ideal para canal com desvanecimento rápido.

## 5.2 TÉCNICAS CLÁSSICAS PARA ESTIMAÇÃO DE CANAL OFDM

No sistema de multiplexação espacial MIMO-OFDM considerado nesse trabalho, a estimação de canal clássica será auxiliada por pilotos, tais quais serão arranjados de acordo com o modo *comb-type*, mostrado na Seção 5.1, Figura 10. As técnicas clássicas escolhidas foram o LS e o MMSE, frequentemente usados na literatura para comparação de desempenho com redes neurais.

### 5.2.1 LEAST SQUARES (LS)

Sendo o sinal recebido após a FFT da forma

$$\mathbf{r}(k) = \mathbf{H}(k)\mathbf{s}(k) + \mathbf{a}(k), \quad (5.1)$$

e o sinal considerando apenas as portadoras piloto é

$$\mathbf{r}_{\mathcal{P}}(k_{\mathcal{P}}) = \mathbf{H}_{\mathcal{P}}(k_{\mathcal{P}})\mathbf{s}_{\mathcal{P}}(k_{\mathcal{P}}) + \mathbf{a}_{\mathcal{P}}(k_{\mathcal{P}}). \quad (5.2)$$

Conforme (BARHUMI; LEUS; MOONEN, 2003) o LS no domínio do tempo pode ser descrito da seguinte forma:

$$\mathbf{V} = \mathcal{F}(\mathbf{I}_{\mathcal{K}}) \quad (5.3)$$

$$\mathbf{F} = \begin{bmatrix} \mathbf{V}^{1,1} & \dots & \mathbf{V}^{1,N_d} \\ \vdots & \ddots & \vdots \\ \mathbf{V}^{P,1} & \dots & \mathbf{V}^{P,N_d} \end{bmatrix} \quad (5.4)$$

$$\mathbf{A} = \text{diag}(\mathbf{s}_{\mathcal{P}})\mathbf{F} \quad (5.5)$$

$$\hat{\mathbf{h}}_{LS} = \mathbf{A}^{-1}\mathbf{r}_{\mathcal{P}}, \quad (5.6)$$

onde  $\mathbf{I}_{\mathcal{K}}$  é uma matriz identidade de tamanho  $\mathcal{K} \times \mathcal{K}$ ,  $\mathcal{F}$  é o operador de FFT,  $p \in [1, 2, \dots, P]$  é o índice de pilotos,  $\mathbf{s}_{\mathcal{P}}$  é o vetor com os pilotos de referência,  $\text{diag}$  é o operador de diagonalização matricial,  $[\cdot]^{-1}$  indica uma inversão matricial e  $\hat{\mathbf{h}}_{LS}$  é o canal estimado no tempo pelo LS. Para obter a estimativa do canal na frequência,  $\hat{\mathbf{h}}_{LS}$  será convertido para a frequência por uma FFT de tamanho  $\mathcal{K}$ <sup>1</sup>, obtendo assim o canal estimado na frequência  $\hat{\mathcal{H}}_{LS}$ .

### 5.2.2 LINEAR MINIMUM MEAN SQUARED ERROR (LMMSE)

O LMMSE faz uso de estatísticas de segunda ordem para minimizar o MSE. Para desenvolver o LMMSE, primeiro define-se o vetor de erro  $e$  da estimação:

$$\mathbf{e} = \mathcal{H} - \hat{\mathcal{H}}, \quad (5.7)$$

onde  $\mathcal{H}$  é o canal original e  $\hat{\mathcal{H}}$  é o canal estimado.

Dessa forma, o MSE é

$$E\{\|\mathbf{e}\|^2\} = E\{\|\mathcal{H} - \hat{\mathcal{H}}\|_2^2\}. \quad (5.8)$$

Assim, segundo (WANG, 2011) a estimação do canal no domínio da frequência pelo LMMSE pode ser calculada por

$$\mathcal{W}(k) = \mathbf{R}_{HH}(k) \left( \mathbf{R}_{HH}(k) + \frac{\beta}{SNR} \mathbf{I}_{\mathcal{K}} \right)^{-1} \quad (5.9)$$

$$\hat{\mathcal{H}}_{LMMSE}(k) = \mathcal{W}(k) \hat{\mathcal{H}}_{LS}(k) \quad (5.10)$$

onde  $\mathcal{W}(k)$  é matriz que usa a correlação em frequência do canal para melhorar a estimação do LS,  $\mathbf{R}_{HH}(k)$  é a matriz de autocorrelação do canal,  $\beta$  é uma constante dependente

<sup>1</sup>O processo de converter o canal estimado no tempo para o domínio da frequência pela FFT de tamanho  $\mathcal{K}$  é conhecido como interpolação baseada em FFT (BARHUMI; LEUS; MOONEN, 2003).

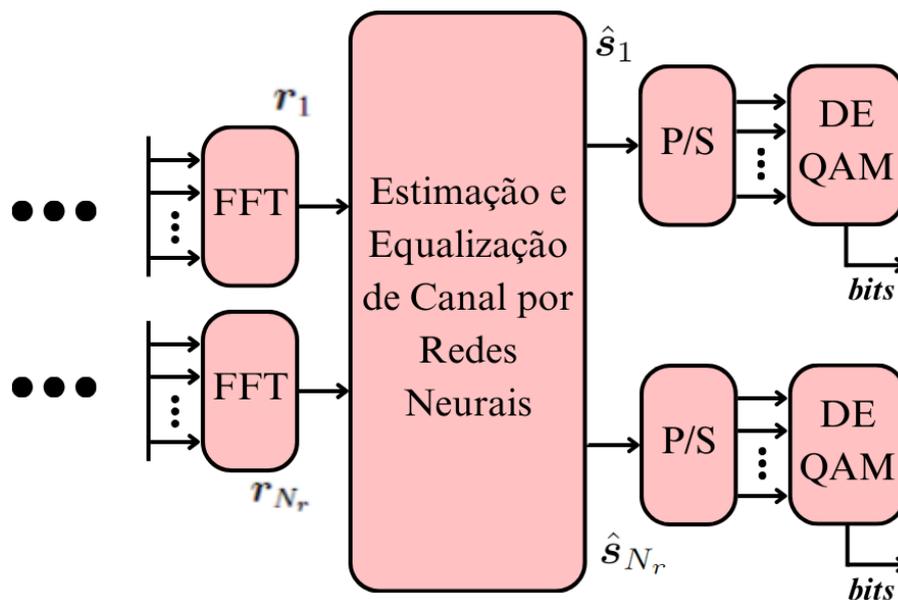
da modulação (JUNIOR, 2017) e SNR é a relação sinal-ruído.

## 6 ESQUEMA PROPOSTO COM REDES NEURAIS ARTIFICIAIS NA ESTIMAÇÃO E EQUALIZAÇÃO DE CANAL

Nesse capítulo, o método proposto para estimação e equalização de canal por redes neurais, os parâmetros da transmissão e recepção do sistema de multiplexação espacial MIMO-OFDM do canal sem fio e das redes neurais utilizadas serão descritos. As simulações do sistema foram feitas na linguagem Python, na versão 3.12.0.

A Figura 6 mostrou o esquemático do sistema MIMO-OFDM considerado com a estimação e equalização de canal feita de acordo com as técnicas clássicas. Por outro lado, a Figura 11 mostra, em uma seção da recepção, como a abordagem por redes neurais é feita. A proposta consiste em estimar e equalizar o canal em uma só tarefa, realizada pela rede neural.

Figura 11 – Sistema Proposto



Fonte: O Autor

Na recepção, após o bloco da FFT, os símbolos recebidos em todas  $N_r$  antenas  $\mathbf{r}_1(k); \dots; \mathbf{r}_1(\mathcal{K}); \dots; \mathbf{r}_{N_r}(k); \dots; \mathbf{r}_{N_r}(\mathcal{K})$  formarão o vetor de entrada da rede. O vetor de entrada é normalizado no intervalo  $[-1, 1]$  para todas as redes neurais desse trabalho, de forma que os valores estejam na mesma escala e a convergência seja aprimorada. Considerando as redes neurais reais e complexas descritas no Capítulo 4 o vetor de entrada tem características específicas para cada caso:

- *Rede Neural Artificial Real*: a RNAR trabalha somente com números reais, mas os símbolos recebidos são complexos. A solução para esse problema é separar cada número complexo em dois números reais, um abaixo do outro:

$$\mathbf{x} \in \mathbb{R}^{2\mathcal{K}N_r} = [\Re\{\mathbf{r}_1(k)\}; \Im\{\mathbf{r}_1(k)\}; \dots; \Re\{\mathbf{r}_1(\mathcal{K})\}; \Im\{\mathbf{r}_1(\mathcal{K})\}; \dots; \Re\{\mathbf{r}_{N_r}(k)\}; \Im\{\mathbf{r}_{N_r}(k)\}; \dots; \Re\{\mathbf{r}_{N_r}(\mathcal{K})\}; \Im\{\mathbf{r}_{N_r}(\mathcal{K})\}]. \quad (6.1)$$

- *Redes Neurais Complexas*: no caso da RNC e RNAS, como visto nas seções anteriores, os números complexos não são um problema. O vetor de entradas dessas redes será

$$\mathbf{x} \in \mathbb{C}^{\mathcal{K}N_r} = [\mathbf{r}_1(k); \dots; \mathbf{r}_1(\mathcal{K}); \dots; \mathbf{r}_{N_r}(k); \dots; \mathbf{r}_{N_r}(\mathcal{K})]. \quad (6.2)$$

Dado que a tarefa da rede neural é transformar  $\mathbf{r}$  em  $\hat{\mathbf{s}}$ , o vetor de saídas desejadas  $\mathbf{d}$  será composto pelos símbolos transmitidos originalmente, concatenados da mesma forma que o vetor de entradas, tanto para a RNAR quanto para RNC e RNAS. Dessa forma, a rede neural fará o mapeamento  $\{\mathbf{r}\} \mapsto \{\hat{\mathbf{s}}\}$ , ou seja, o processo de estimar o canal e então equalizá-lo de forma conjunta. Esse processo será caracterizado por um treinamento *offline*, onde um lote de símbolos OFDM gerados aleatoriamente será usado para treinamento, de forma que a solução proposta por redes neurais não faz uso de pilotos.

## 6.1 PARÂMETROS DE SIMULAÇÃO

A Tabela 5 mostra os parâmetros da transmissão por multiplexação espacial MIMO-OFDM. Além disso, um préambulo das comunicações é considerado, usando 1000 símbolos OFDM, assim como definido na Tabela 5. Dos 1000 símbolos, 700 (70%) serão usados para o treinamento *offline* da rede neural e 300 (30%) para a validação. A estimação de canal clássica utiliza o arranjo de pilotos *comb-type* e a taxa de pilotos 1/4 significa que das 64 subportadoras, 16 são pilotos. O CP de 15 foi escolhido para garantir que todos os impulsos do canal fossem cobertos.

Tabela 5 – Parâmetros do Sistema MIMO-OFDM

<b>Parâmetros MIMO-OFDM</b>	
MIMO	2x2
Taxa de Pilotos (LS e MMSE)	1/4
Símbolos OFDM	1000
Subportadoras $\mathcal{K}$	64
Espaç. entre Subportadoras	240kHz
CP	15
Modulação	4-QAM

Fonte: O Autor

A Tabela 6 mostra os parâmetros do canal sem fio. O modelo TDL-A considera um canal seletivo em frequência. A implementação do canal é de autoria de Mayer (MAYER, 2022).

Tabela 6 – Parâmetros do Canal Sem Fio

<b>Parâmetros do Canal Sem Fio</b>	
Perfil de Atraso	<i>TDL-A</i>
<i>Delay Spread</i>	100ns
Amplitude dos Atrasos	-15.9 a 0dB
Desvanecimento	<i>Rayleigh</i>

Fonte: O Autor

A Tabela 7 mostra os parâmetros utilizados nas redes neurais, desde neurônios em cada camada até o tipo de inicialização dos pesos e *bias*. Nessa tabela,  $I^{[l]}$  é o número de neurônios na camada  $l$ ,  $f^{[l]}$  é a função de ativação na camada  $l$ ,  $\eta_w$  e  $\eta_b$  são as taxas de aprendizado, *atanh*, *tanh* e *linear* se referem à função de ativação arco-tangente hiperbólica, tangente hiperbólica e linear, respectivamente. A inicialização dos pesos e *bias* é definida por  $\alpha_w$  e  $\alpha_b$ , respectivamente, onde *glorot* se refere à distribuição Glorot (GLOROT; BENGIO, 2010), *normal* é a distribuição normal aleatória e *zeros* indica que aquele parâmetro se iniciará com o valor zero. A RNAR desse trabalho foi implementada utilizando a biblioteca Tensorflow Keras (ABADI et al., 2015), enquanto a RNC e RNAS foram implementadas utilizando a biblioteca RosenPy (CRUZ; MAYER; ARANTES, 2022).

Os parâmetros foram selecionados inicialmente com base nos trabalhos de (MAYER, 2022), (SOUSA et al., 2023) e (YE; LI; JUANG, 2018) e posteriormente a partir de tentativa e erro buscando uma estrutura otimizada. A estrutura com duas camadas escondidas

da RNAR foi a que apresentou melhor desempenho, sendo que o número de neurônios escolhidos se deve ao fato de que os resultados para menos neurônios não foram satisfatórios e os resultados para mais neurônios são pouco superiores e muito mais pesados computacionalmente. A RNC e a RNAS se mostraram bastante sensíveis a mudanças de parâmetros, de forma que adicionar mais camadas ou aumentar o número de neurônios causava problemas na convergência dessas redes.

Tabela 7 – Parâmetros das Redes Neurais

	$I^{[0]}$	$I^{[1]}$	$I^{[2]}$	$I^{[3]}$	$\eta_w$	$\eta_b$	Épocas
RNAR	$2\mathcal{K}N_r$	1024	1024	$2\mathcal{K}N_t$	0.001	0.001	100
RNC	$\mathcal{K}N_r$	2048	$\mathcal{K}N_t$	—	0.001	0.001	100
RNAS	$\mathcal{K}N_r$	2048	$\mathcal{K}N_t$	—	0.001	0.001	100

	$f^{[0]}$	$f^{[1]}$	$f^{[2]}$	$f^{[3]}$	$\alpha_w$	$\alpha_b$	—
RNAR	—	<i>tanh</i>	<i>tanh</i>	<i>linear</i>	<i>glorot</i>	<i>zeros</i>	—
RNC	—	<i>atanh</i>	<i>linear</i>	—	<i>normal</i>	<i>zeros</i>	—
RNAS	—	<i>tanh</i>	<i>linear</i>	—	<i>normal</i>	<i>zeros</i>	—

Fonte: O Autor

## 6.2 RESULTADOS DE SIMULAÇÃO

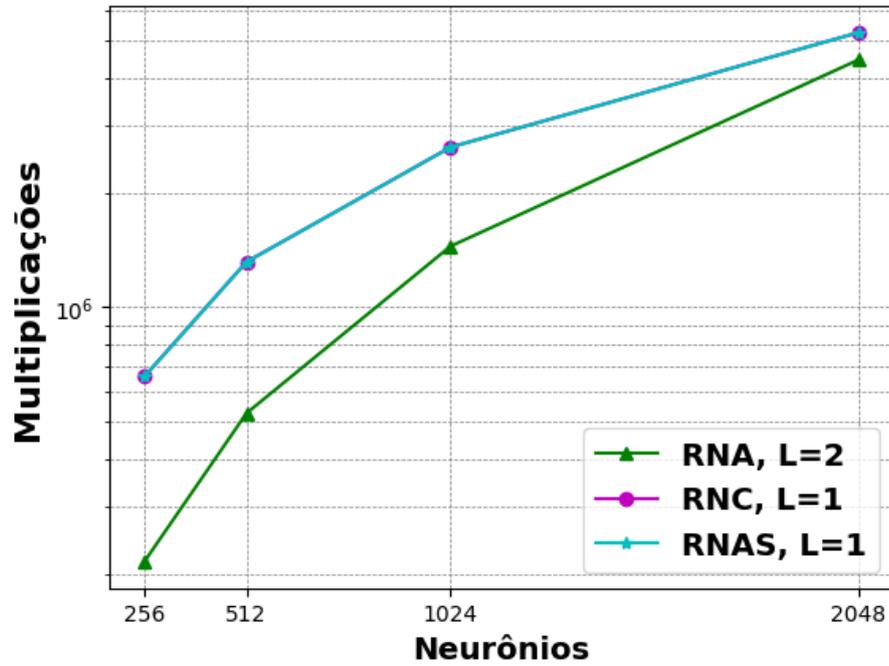
A partir do equacionamento definido pelas Tabelas 2, 3 e 4, estima-se a complexidade computacional de cada iteração das redes neurais a partir do número de multiplicações, que é a operação mais recorrente dessas arquiteturas.

Em todos os resultados, exceto quando é dito o contrário, para cada cenário de  $E_b/N_0$ , as redes neurais foram treinadas e validadas nessa mesma  $E_b/N_0$ . Isso significa que uma rede neural treinada em 0 dB é validada em 0 dB, uma rede neural treinada em 20 dB é validada em 20 dB e assim por diante. Além disso, os resultados de BER e MSE para as redes são calculados a partir dos dados de validação e na Seção 6.2.1, Figura 20, numa nova etapa denominada etapa de teste.

As Figuras 12 e 13 mostram o número de multiplicações realizadas pelas redes neurais no treinamento e na validação, respectivamente. Nessas Figuras,  $L$  indica o número de camadas escondidas de cada arquitetura e no eixo das abscissas os valores indicam o total de neurônios considerando todas essas camadas escondidas. O fato da RNAR possuir duas camadas faz com que seu número de operações seja maior que a RNC e RNAS, que só possuem uma. Apesar disso, de acordo com os parâmetros usados nesse trabalho,

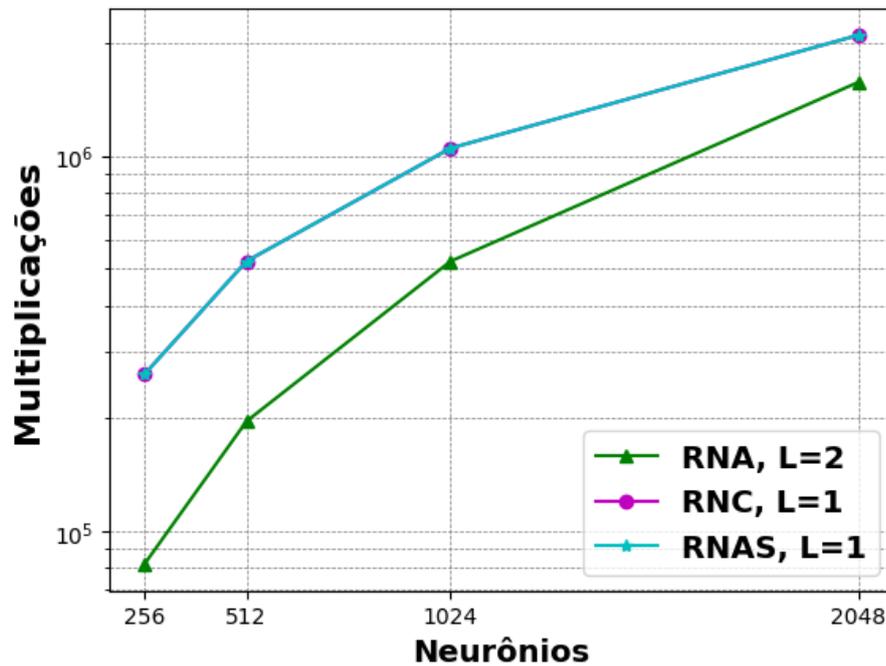
que equivalem ao valor de 2048 neurônios no eixo das abscissas nas Figuras 12 e 13, a RNAR é a arquitetura que menos custa computacionalmente no intervalo considerado. A RNC e RNAS possuem uma diferença de operações muito pequena no treinamento, sendo imperceptível pelo gráfico. Na validação, o número de operações é o mesmo.

Figura 12 – Treinamento



Fonte: O Autor

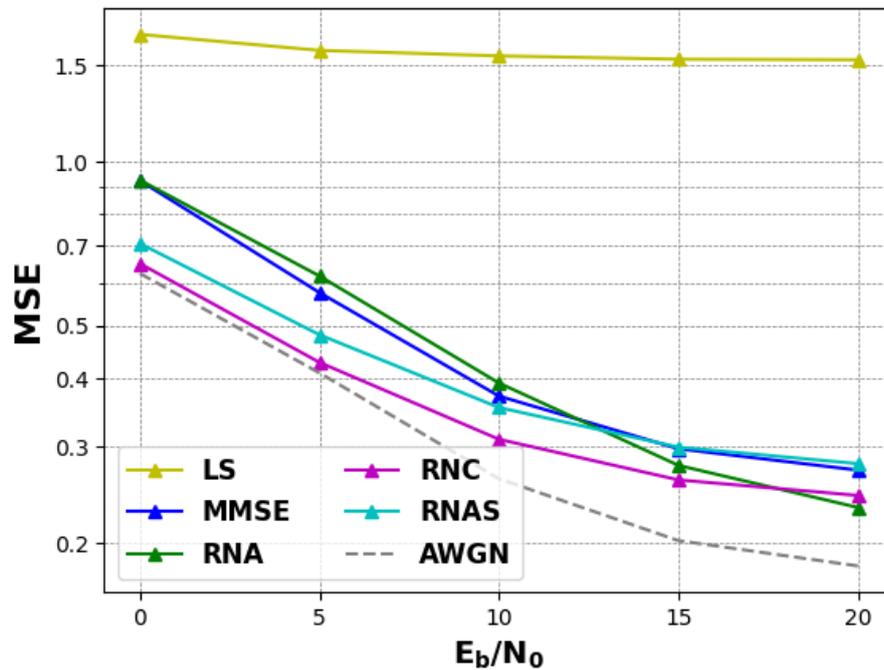
Figura 13 – Validação



Fonte: O Autor

Na Figura 14 o MSE da validação é avaliado entre os símbolos recebidos e os símbolos transmitidos para as redes neurais, técnicas clássicas e cenário de conhecimento perfeito do canal, indicado pelo gráfico por AWGN, com uma variação de  $E_b/N_0$  de 0 a 20 dB. Nota-se que com a técnica clássica LS, o resultado é pior que todas outras técnicas, pois ele não consegue lidar com a interferência dos diferentes símbolos na recepção, dada sua simplicidade. O MMSE, por outro lado, performou similarmente às rede neurais, mas no geral foi um pouco pior, com exceção de 15 e 20 dB, onde ultrapassou a RNAS, fato que se deve ao uso de estatísticas do canal. Os valores de MSE das redes complexas se mostraram parecidos, de forma que a RNC teve um erro um pouco menor que a RNAS em toda faixa de  $E_b/N_0$ , mostrando que a RNC não sofreu com problemas de instabilidade. Ao desconsiderar o LS, nota-se que a RNAR obtém a pior performance entre 0 e 10 dB, mas supera o MMSE e a RNAS a partir de 15 dB e por fim a RNC em 20 dB. Deve-se observar que os resultados obtidos para as redes e para o MMSE mostraram valores similares em 20 dB, por exemplo, a RNAR, RNC, RNAS e MMSE obtiveram um MSE de 0.2320, 0.2441, 0.2792 e 0.2717 respectivamente, de forma que outras métricas como a BER podem não se comportar do mesmo modo.

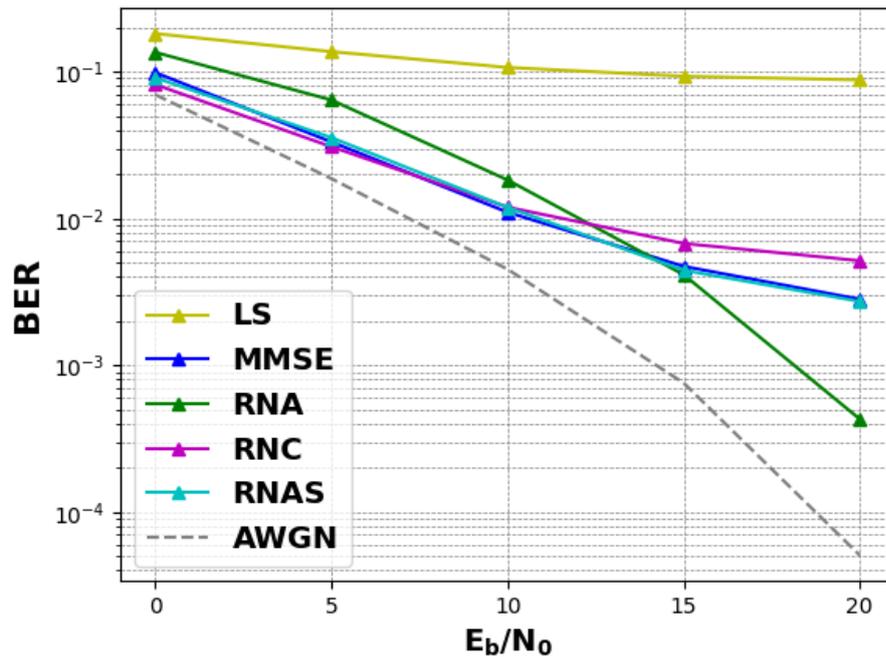
Figura 14 – Desempenho de MSE das técnicas clássicas e redes neurais



Fonte: O Autor

A Figura 15 mostra a BER para as redes neurais, técnicas clássicas e cenário de conhecimento perfeito do canal, com variação de  $E_b/N_0$  de 0 a 20 dB. Tanto MMSE quanto LS mantiveram um comportamento similar aos resultados de MSE, sendo que o MMSE supera a RNC e se iguala a RNAS em quase toda região de  $E_b/N_0$  considerada, mas é superado pela RNAR a partir  $E_b/N_0 = 15$  dB, mesmo que o MMSE seja um algoritmo pouco prático e foi simulado com estatísticas que consideram o conhecimento perfeito do canal. As curvas de BER mostram similaridades com as do MSE, mas não seguem exatamente o mesmo padrão. Os valores de BER apresentam a RNAS com um desempenho praticamente igual ao MMSE, enquanto a RNC, rede que teve o menor MSE (exceto em 20 dB), inicialmente é melhor, mas a partir de 10 dB, perde desempenho, apesar de não ser grande a diferença dessa para a RNAS e o MMSE. A RNAR, que se destaca negativamente de 0 a 10 dB, por outro lado, obtém a menor BER a partir de 15 dB, alcançando um resultado que se destaca em 20 dB, dado o fato de que conseguiu convergir com duas camadas escondidas em sua arquitetura.

Figura 15 – Desempenho de BER das técnicas clássicas e redes neurais

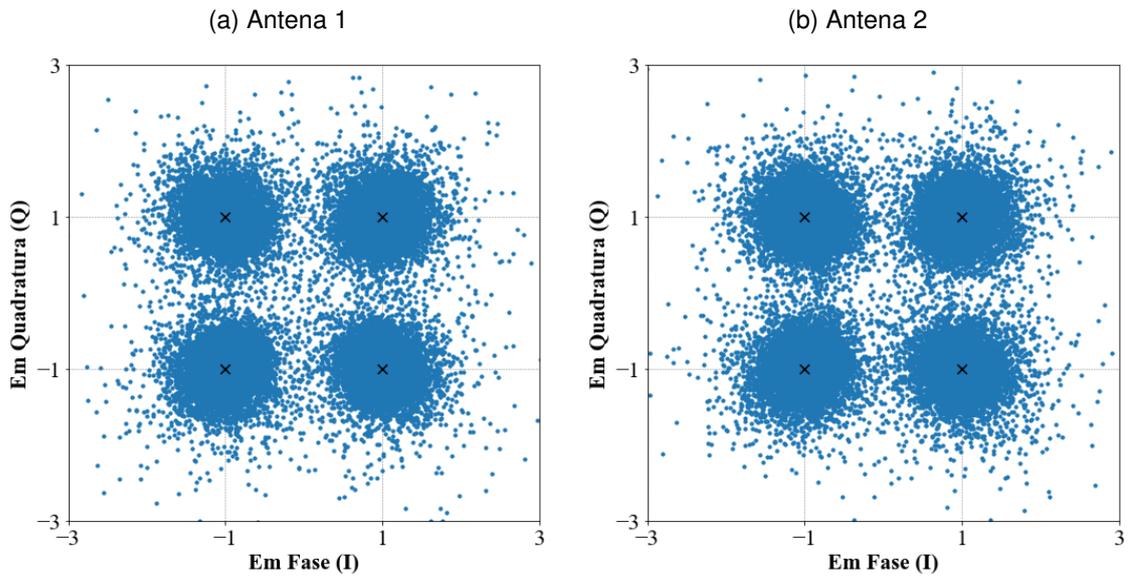


Fonte: O Autor

As arquiteturas que melhor funcionaram para as redes complexas nesse trabalho foram de apenas uma camada escondida com muitos neurônios, enquanto RNAR foi definida com duas camadas um pouco menores, resultando em menos complexidade computacional mas uma menor sensibilidade a regiões de baixa potência de sinal. No treinamento, considerando as duas redes neurais com os melhores resultados, de acordo com a Figura 15, a RNAR faz 4464128 multiplicações e a RNAS, 5260032. Os resultados de BER concordam com trabalhos da literatura como (SOUSA et al., 2023) e (YE; LI; JUANG, 2018), que trabalham com essa proposta de estimação e equalização conjunta.

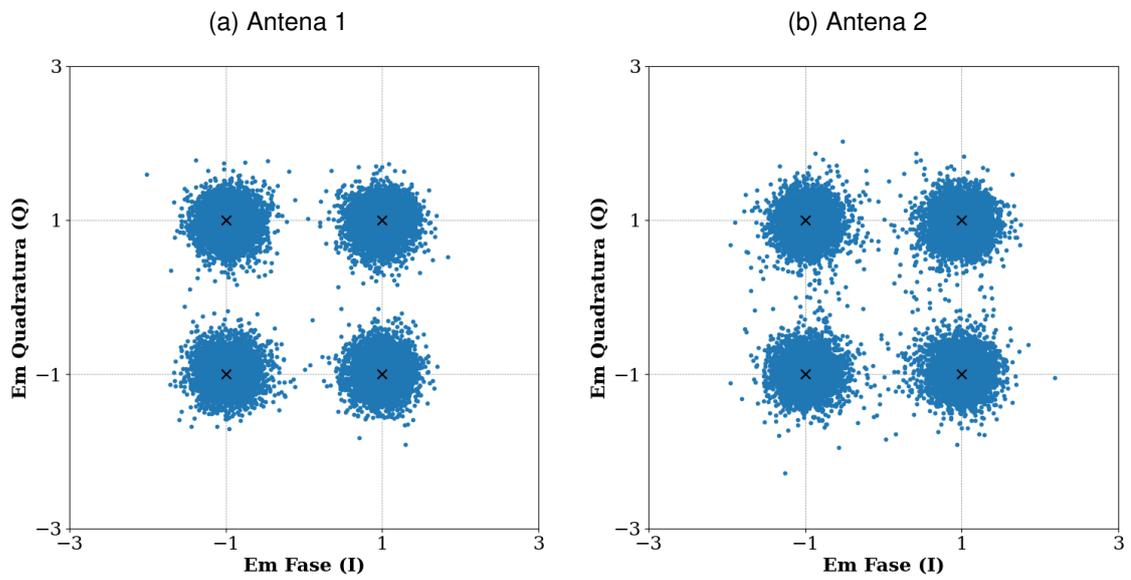
As Figuras 16, 17, 18 e 19 mostram a constelação (símbolos recebidos) em cada uma das antenas para o MMSE, RNAR, RNC e RNAS, em um cenário de 20 dB, respectivamente. Apesar das curvas de BER já mostrarem isso, as nuvens de símbolos da RNAR são mais concentradas e possuem menos símbolos espalhados. O MMSE e a RNAS mostram um padrão similar de espalhamento e a RNC aparenta uma tendência de erros na região central da constelação.

Figura 16 – Constelação de símbolos recebidas nas antenas receptoras usando o MMSE



Fonte: O Autor

Figura 17 – Constelação de símbolos recebidas nas antenas receptoras usando a RNAR



Fonte: O Autor

Figura 18 – Constelação de símbolos recebidas nas antenas receptoras usando a RNC

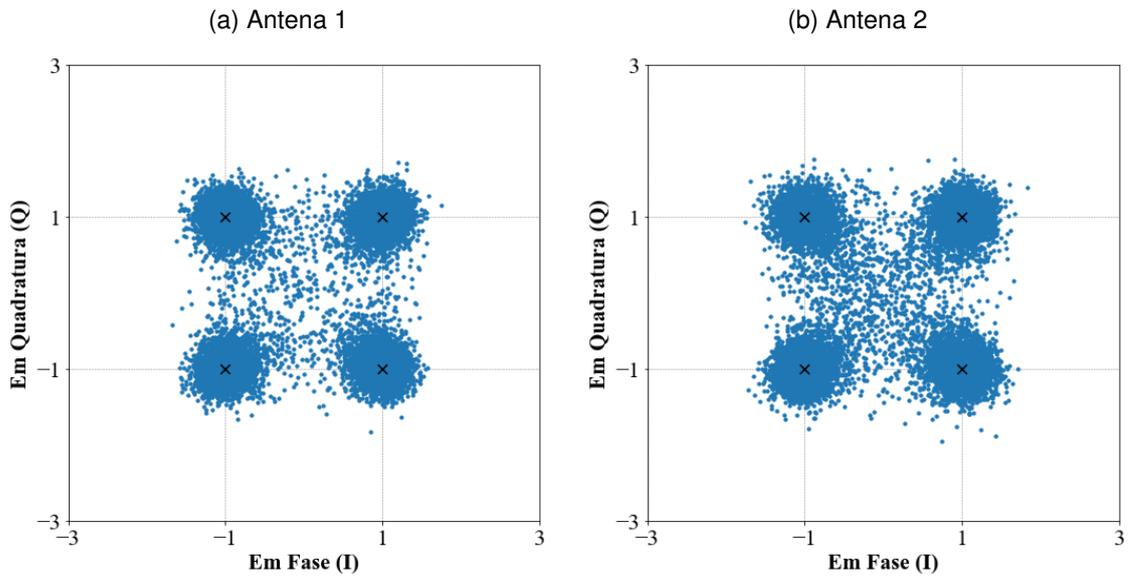
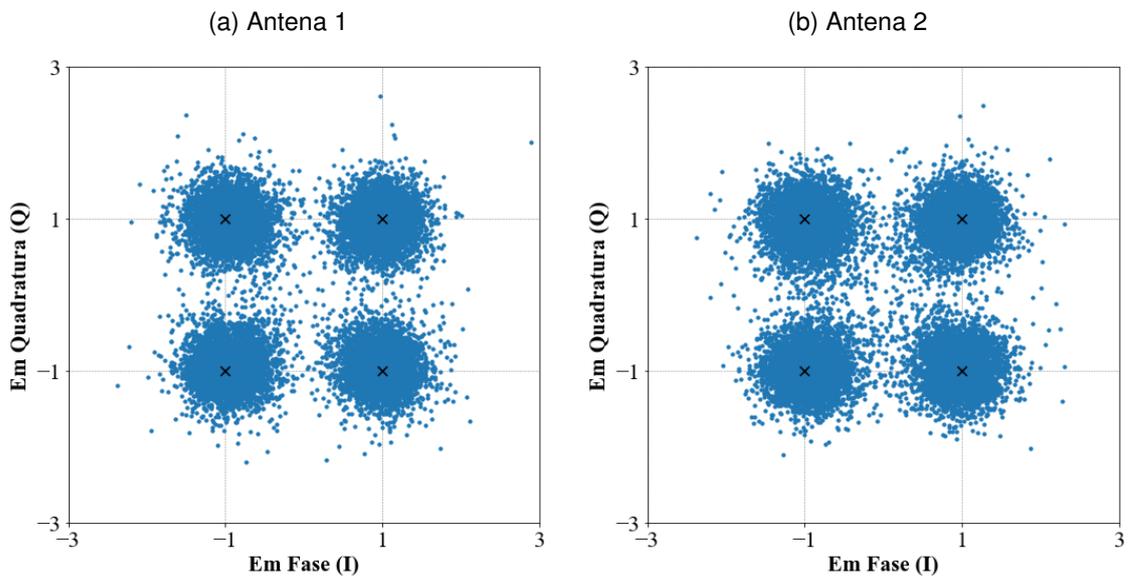


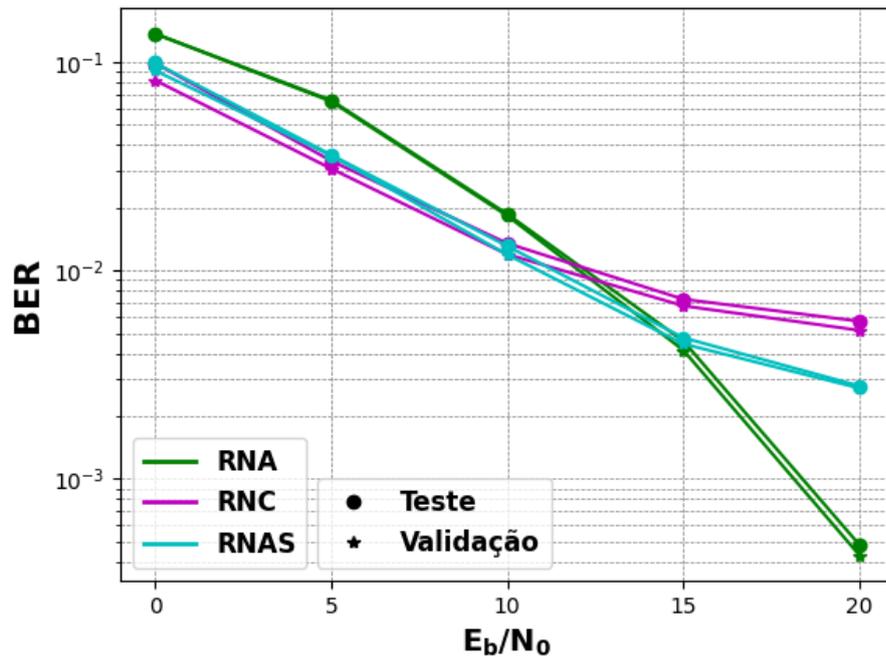
Figura 19 – Constelação de símbolos recebidas nas antenas receptoras usando a RNAS



### 6.2.1 Etapa de Teste das Redes Neurais

Na literatura sobre ML, uma rede neural pode ter uma etapa além do treinamento e da validação, o teste. O treinamento e a validação estão associados com o ajuste fino dos parâmetros da rede neural, enquanto o teste tem o intuito de comprovar a capacidade

Figura 20 – Desempenho de BER na Fase de Teste das Redes Neurais Artificiais



Fonte: O Autor

do modelo treinado. A fase de teste consiste em introduzir dados novos no sistema, geralmente do com o mesmo número de amostras da validação e no caso desse trabalho, aplicar o modelo treinado para realizar a estimação e equalização conjunta. Dos 1000 símbolos considerados como a base de dados das redes nesse trabalho, 700 símbolos OFDM são usados no treinamento e 300 na validação. Para o teste, 300 novos símbolos foram gerados nas mesmas condições dos anteriores.

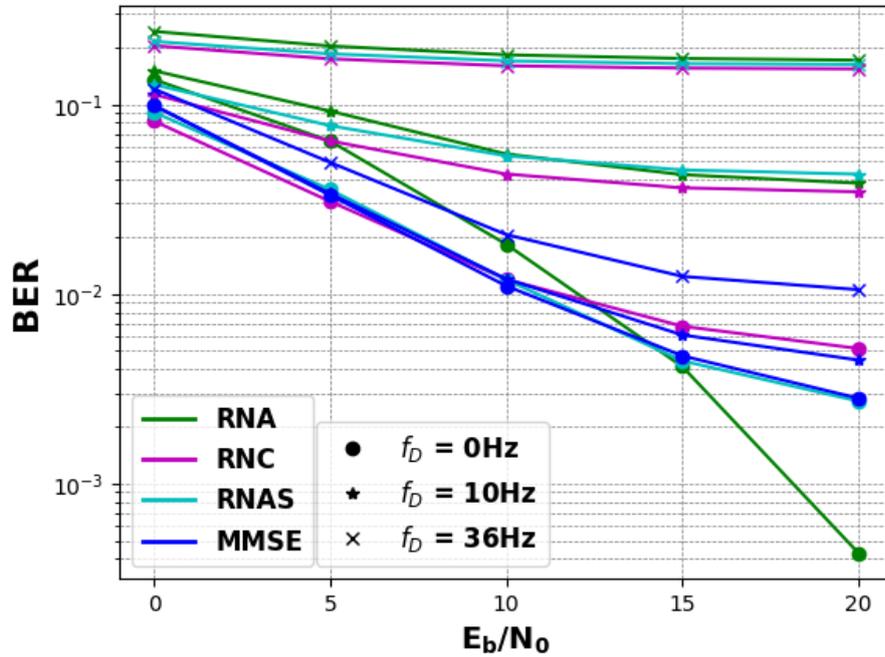
A Figura 20 mostra que, caso não haja uma mudança significativa no ambiente da transmissão, as redes neurais são capazes de desempenhar da mesma forma sem haver a necessidade de retrainar o modelo.

### 6.2.2 Impacto do Efeito Doppler

Em um sistema de comunicação móvel, receptores em movimento sofrem com desvios de frequência causados pelo efeito Doppler (ver Seção 3.1). A Figura 21 mostra as rede neurais e o MMSE atuando em um sistema com diferentes níveis desse efeito. Quando  $f_D = 10\text{Hz}$  (3km/h), somente o MMSE, que usa informações estatísticas do conhecimento perfeito do canal, não sofreu uma grande degradação no resultado, situação que se deve a essas estatísticas do canal não terem mudado tanto apesar da mobilidade. Para  $f_D = 36\text{Hz}$ , as redes neurais não foram capazes de lidar com o doppler nem mesmo em um cenário de alta  $E_b/N_0$ , mostrando uma fragilidade dessa solução com as arquitetu-

ras totalmente conectadas consideradas.

Figura 21 – Desempenho de BER das Redes Neurais Artificiais e do MMSE em um Cenário com Doppler

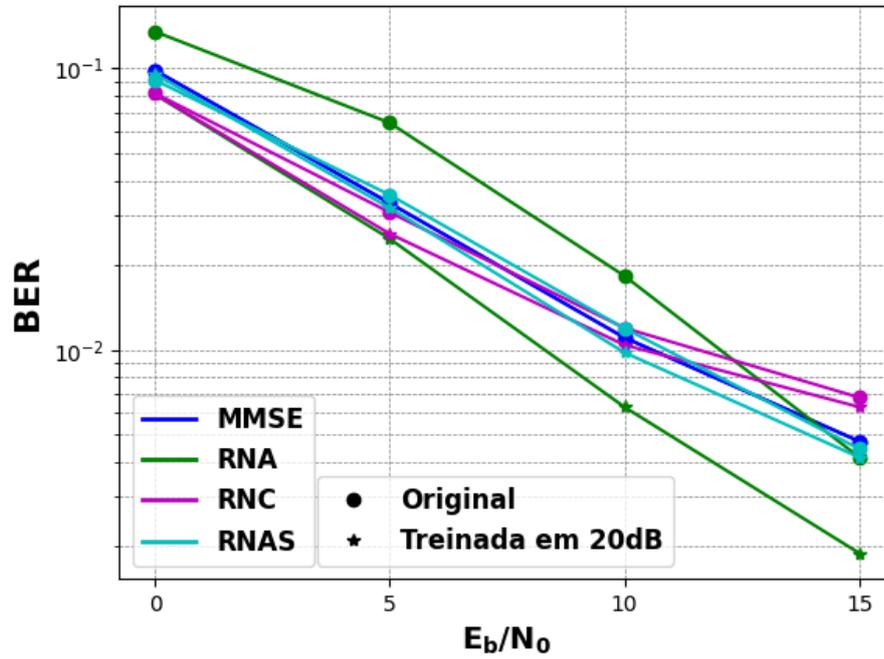


Fonte: O Autor

### 6.2.3 Robustez à Variação de $E_b/N_0$ em um Modelo Treinado

As Figuras 22 e 23 mostram casos onde o modelo treinado em uma  $E_b/N_0$  e foi aplicado em cenários diferentes. A performance vista na Figura 22 é como esperada pois a rede treinada em 20 dB mostra resultados melhores para  $E_b/N_0 \in [0, 15]$  dB do que os valores originais, que se referem a quando a rede é treinada em um valor e validada nesse mesmo valor. Isso mostra que o treinamento em uma  $E_b/N_0$  maior faz com que a rede neural crie um modelo mais robusto e que por consequência performa melhor. A motivação disso é que em 20 dB, com um sinal mais potente, a rede neural tem uma situação vantajosa para compreender as complexidades do canal sem fio. Nesse cenário, a única situação em que o MMSE supera alguma rede treinada é quando comparado com a RNC, em 20 dB.

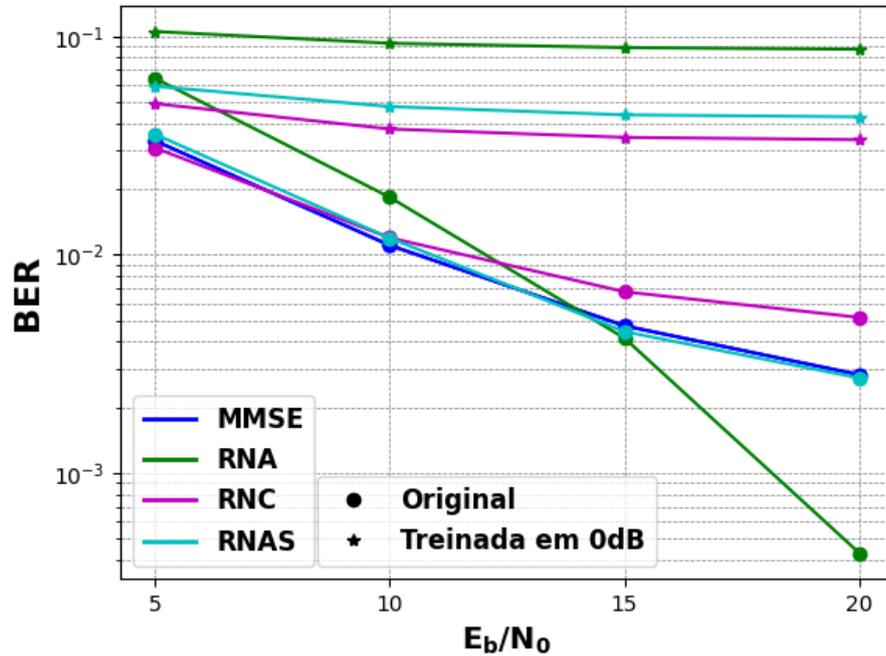
Figura 22 – Desempenho de BER das Redes Neurais Artificiais Treinadas para  $E_b/N_0 = 20$  dB e Validadas para  $E_b/N_0 \in [0, 15]$  dB



Fonte: O Autor

Em vista do resultado anterior visto na Figura 22, a Figura 23 mostra o esperado: o modelo treinado em 0 dB tem uma performance pior quando usado nos outros cenários, dada a grande influência do ruído nesse cenário.

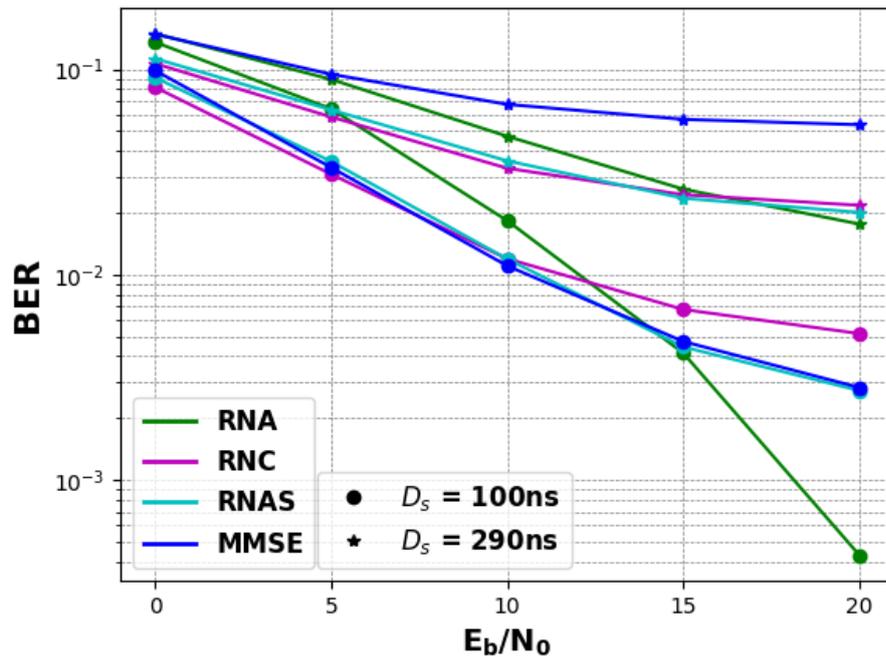
Figura 23 – Desempenho de BER das Redes Neurais Artificiais Treinadas para  $E_b/N_0 = 0$  dB e Validadas para  $E_b/N_0 \in [5, 20]$  dB



Fonte: O Autor

#### 6.2.4 Impacto do *Delay Spread*

O  $D_s$ , que nesse trabalho foi o mostrado na Tabela 6, impacta diretamente a performance do sistema, pois seguindo o modelo TDL-A, o  $D_s$  maior significa mais ecos atrasados do sinal chegando na recepção. Para obter os resultados da Figura 24, as redes foram retreinadas com o novo  $D_s$ . Essa Figura mostra que as redes mantiveram a tendência de resultados, mas com degradação grande dos mesmos, especialmente no caso da RNAR. O MMSE foi a técnica que pior performou para esse caso, pois apesar de sua natureza, não cria um modelo que busca entender como se deu esse aumento do  $D_s$  como fazem as redes neurais.

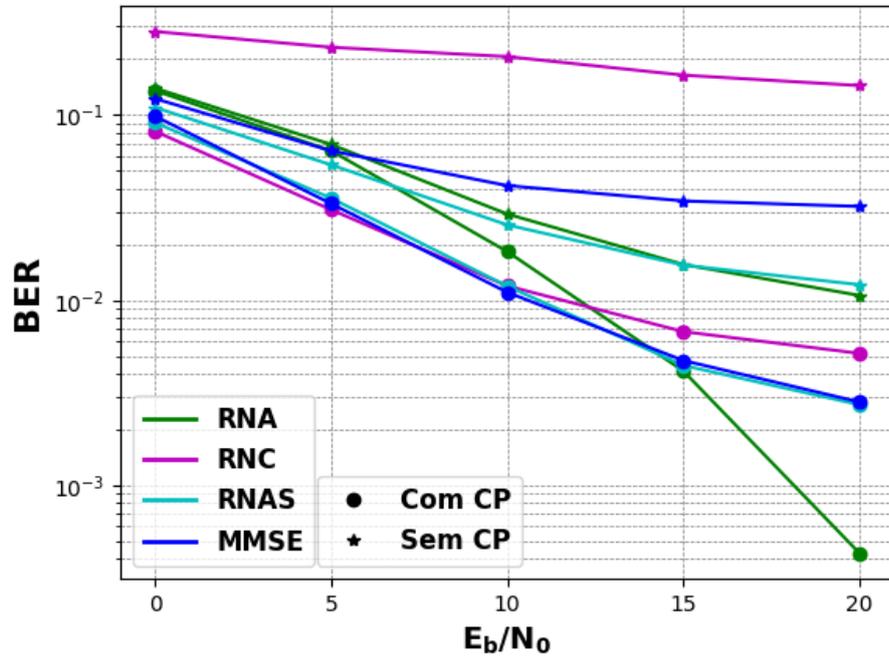
Figura 24 – Desempenho de BER das Redes Neurais Artificiais e do MMSE com Aumento do *Delay Spread*

Fonte: O Autor

### 6.2.5 Impacto do CP

Um teste interessante considerando redes neurais na estimação e equalização de canal conjunta em sistemas OFDM é o impacto do prefixo cíclico (CP) (SOUSA et al., 2023; YE; LI; JUANG, 2018), onde as redes neurais foram retreinadas para o caso da ausência do CP. Por isso, na Figura 25, as redes neurais e o MMSE foram testados em um cenário de transmissão OFDM no pior caso, onde não há CP para cobrir os atrasos do canal e então haverá o problema da ISI. Como esperado, ocorre uma queda de performance por parte de todas técnicas analisadas, sendo que a RNC foi a única que não conseguiu lidar com o problema proposto, pois sofreu com o problema de instabilidade no treinamento por causa de sua função de ativação complexa e isso impactou na descida do gradiente. O MMSE e a RNAR tiveram degradações grandes, enquanto a RNAS foi a menos impactada, mostrando que as redes neurais, no geral, são robustas para esse caso, mas o MMSE não. Novamente, isso pode ser atribuído diretamente ao fato de que uma rede neural será treinada com esse cenário ruim em consideração, "compreendendo" ele.

Figura 25 – Desempenho de BER das Redes Neurais Artificiais e do MMSE sem o Prefixo Cíclico do Símbolo OFDM



Fonte: O Autor

## 7 CONCLUSÃO

Nesse trabalho a estimação e equalização conjunta por redes neurais em um sistema de multiplexação espacial MIMO-OFDM foi proposta. Essa ideia surge do fato de que as redes neurais são algoritmos com uma capacidade poderosa de detectar padrões e tendências, gerando um modelo capaz de entender o canal de comunicação sem fio e o necessário para retirar o seu efeito do sinal recebido.

O sistema implementado considerou o sincronismo perfeito entre transmissor e receptor, focando no problema causado pelo canal multipercurso (sem linha de visada). A modulação, transmissão OFDM, canal, ruído, recepção OFDM e demodulação foram os blocos utilizados. Os resultados foram demonstrados em termos de BER, MSE entre símbolos transmitidos e recebidos e também as constelações desses símbolos, com variações de  $E_b/N_0$ . Além disso, análises de robustez em cenários adversos foram feitas, incluindo fase de teste das redes, impacto do efeito doppler, modelos treinados atuando em condições diferentes do treino, impacto do *delay spread* e impacto do CP.

Os resultados foram validados em um modelo de canal sem fio seletivo em frequência com multipercursos disponibilizado pelo 3GPP nas normas do 5G para se aproximar de uma situação real possível. Eles mostram que as três redes neurais conseguem realizar a tarefa proposta performando melhor que o LS em todos casos e melhor que o MMSE na maioria dos casos. Sem considerar o LS, a RNAR tem o pior desempenho até 10 dB e o melhor a partir de 15 dB, enquanto a RNC, que em 0 e 5 dB é a melhor, tem o pior resultado a partir de 15 dB. A RNAS e o MMSE performam praticamente igual em todo intervalo, mas em 20 dB a RNAR supera essas técnicas.

Análises de robustez foram feitas para avaliar as redes em cenários adversos. Quando treinadas em 20 dB, assim como esperado, as redes mostraram melhor performance e o contrário ocorreu com o treino em 0 dB. No cenário com efeito Doppler, as estatísticas do MMSE fizeram com que os resultados dessa técnica não mudassem muito, enquanto que as redes neurais tiveram grande queda de performance em 10 e 36Hz. Em contrapartida, nos casos onde não havia CP e o  $D_s$  aumentou, elas superam o MMSE, com exceção de um caso para o cenário sem CP, no qual a RNC teve um resultado bem pior, pois teve problemas de estabilidade na ativação.

A partir desses resultados, pode-se concluir que as redes neurais artificiais são aplicáveis para a estimação e equalização de canal em sistemas de multiplexação espacial MIMO-OFDM em canais. Nota-se que a depender do nível do sinal e seguindo os parâmetros da Subseção 6.1, uma rede pode performar melhor que outras em termos de BER, pois a RNC, tem o melhor resultado entre 0 e 5 dB, a RNAS em 10 dB e a RNAR a partir 15 dB. A RNC tem o problema quanto ao risco de instabilidade dada a natureza das funções de ativação complexas, e por isso mostra bons resultados em  $E_b/N_0$  baixa. A

RNAR se beneficia em regiões de alta potência do sinal pelo fato de possuir duas camadas, consegue obter um modelo mais preciso. A RNAS, assim como a RNC, teve o melhor funcionamento com apenas uma camada escondida. A RNAS evita o problema da instabilidade que a RNC possui mas sofre com a representação da fase por causa da ativação separada e no seu melhor resultado, em 10 dB, não performa tão diferente da RNC, se mostrando a pior das opções.

Mesmo que a complexidade computacional das redes neurais seja maior que o LS e o MMSE, o LS tem um desempenho ruim e as redes não são tão pouco práticas como o MMSE, que tem seus resultados de simulação com uso de estatísticas do canal perfeito. Apesar disso, no cenário atual, complexidades computacionais maiores podem ser reduzidas por computação paralela por implementação em uma *Field Programmable Gate Array* (FPGA), usando linguagem de descrição de hardware (SUMAYYABEEVI et al., 2021).

Em trabalhos futuros, o uso de outras redes neurais, especialmente a rede complexa PTRBF, é de grande interesse. Além disso, analisar outros parâmetros no sistema, como: número de subportadoras, outras modulações, maior número de antenas e dividir o problema em partes menores.

## REFERÊNCIAS

3GPP. *3GPP - The Mobile Broadband Standard*. 2024. Disponível em: <<https://www.3gpp.org/>>.

ABADI, M. et al. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>.

ANDREWS, J. G. et al. What will 5g be? **IEEE Journal on Selected Areas in Communications**, v. 32, n. 6, p. 1065–1082, 2014.

\_\_\_\_\_. Femtocells: Past, present, and future. **IEEE Journal on Selected Areas in Communications**, v. 30, n. 3, p. 497–508, 2012.

BARHUMI, I.; LEUS, G.; MOONEN, M. Optimal training design for mimo ofdm systems in mobile wireless channels. **Signal Processing, IEEE Transactions on**, v. 51, p. 1615 – 1624, 07 2003.

BAYKAS, T. et al. Ieee 802.15.3c: the first ieee wireless standard for data rates over 1 gb/s. **IEEE Communications Magazine**, v. 49, n. 7, p. 114–121, 2011.

CHO, Y. S. **MIMO-OFDM Wireless Communications with MATLAB**. Singapore: John Wiley & Sons (Asia) Pte Ltd, 2010. 457 p.

CLARKE, T. Generalization of neural networks to the complex plane. **INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), June 1990, San Diego, USA.**, p. 435–440, 1990.

CRUZ, A. A.; MAYER, K. S.; ARANTES, D. S. RosenPy: an Open Source Python Framework for Complex-Valued Neural Networks. **Software X**, 2022.

ELSHOKRY, A. M. **Complexity and Performance Evaluation of Detection Schemes for Spatial Multiplexing MIMO Systems**. 2010. 102 21. Tese (Mestrado em Engenharia Elétrica) — Islamic University Gaza, Gaza, Palestine, 2010.

ETSI. **5G; Study on channel model for frequencies from 0.5 to 100 GHz (3GPP TR 38.901 version 16.1.0 Release 16)**. [S.l.], 2020.

\_\_\_\_\_. **5G; NR; Base Station (BS) Radio Transmission and Reception**. [S.l.], 2022.

FAZEL, K.; KAISER, S. **Multi-carrier and spread spectrum systems: from OFDM and MC-CDMA to LTE and WiMAX, 2 ed.** [S.l.]: John Wiley & Sons, Ltd, 2008.

GLOTOT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. **Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics**, PMLR, Chia Laguna Resort, Sardinia, Italy, v. 9, p. 249–256, 13–15 May 2010.

GRAMI, A. Chapter 12 - wireless communications. In: GRAMI, A. (Ed.). **Introduction to Digital Communications**. Boston: Academic Press, 2016. p. 493–527. ISBN

978-0-12-407682-2. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780124076822000120>>.

HAYKIN, S. **Neural Networks, 2nd ed.** Upper Saddle River, New Jersey: Patience Hall, 1999.

HAYKIN, S.; MOHER, M. **Sistemas modernos de comunicações wireless.** [S.l.]: Bookman, 2009. ISBN 9788577801558.

HEATH, R. W. et al. An overview of signal processing techniques for millimeter wave mimo systems. **IEEE Journal of Selected Topics in Signal Processing**, v. 10, n. 3, p. 436–453, 2016.

HSIEH, M.-H.; WEI, C.-H. Channel estimation for ofdm systems based on comb-type pilot arrangement in frequency selective fading channels. **IEEE Transactions on Consumer Electronics**, v. 44, n. 1, p. 217–225, 1998.

JUNIOR, H. R. A. B. **ESTIMAÇÃO DE CANAL EM SISTEMAS OFDM UTILIZANDO REDES NEURAIS ARTIFICIAIS RBF COM TRANSMITÂNCIA DE FASE.** 2017. Tese (Doutorado) — PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL, 2017.

KANG, X.-F.; LIU, Z.-H.; YAO, M. Deep learning for joint pilot design and channel estimation in mimo-ofdm systems. **Sensors**, v. 22, n. 11, 2022. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/22/11/4188>>.

KIM, T.; ADALI, T. Fully complex multi-layer perceptron network for nonlinear signal processing. **VLSI Signal Processing**, v. 32, p. 29–43, 08 2002.

\_\_\_\_\_. Approximation by fully complex multilayer perceptrons. **Neural computation**, v. 15, p. 1641–66, 08 2003.

MAYER, K. S. **REDES NEURAIS SOB DOMÍNIO COMPLEXO E APLICAÇÕES EM TELECOMUNICAÇÕES.** 2022. 164 p. Tese (Doutorado em Engenharia Elétrica) — UNIVERSIDADE ESTADUAL DE CAMPINAS, Campinas, 2022.

NGUYEN, H. L. T. V. C. T. N. H. C. V. Machine learning-based 5g-and-beyond channel estimation for mimo-ofdm communication systems. **Sensors**, **21**, 4861., 2021.

REDDY, B. R. K. **MIMO Detection.** 2010. 30 f. Dissertação (Master of Technology) — Indian Institute of Technology Hyderabad, Ordinance Factory Estate, Yeddumailaram, 2010.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

SAVITHA, R.; SURESH, S.; SUNDARARAJAN, N. Metacognitive Learning in a Fully Complex-Valued Radial Basis Function Neural Network. **Neural Computation**, v. 24, n. 5, p. 1297–1328, 05 2012. ISSN 0899-7667. Disponível em: <[https://doi.org/10.1162/NECO\\_a\\_00254](https://doi.org/10.1162/NECO_a_00254)>.

SOLEIMANI, B.; SABBAGHIAN, M. Cluster-based resource allocation and user association in mmwave femtocell networks. **IEEE Transactions on Communications**, v. 68, n. 3, p. 1746–1759, 2020.

SOUSA, H. et al. Cvnn-based channel estimation and equalization in ofdm systems without cyclic prefix. 08 2023.

SUMAYYABEEVI, V. et al. A new hardware architecture for fpga implementation of feed forward neural networks. In: **2021 2nd International Conference on Advances in Computing, Communication, Embedded and Secure Systems (ACCESS)**. [S.l.: s.n.], 2021. p. 107–111.

TSE, D.; VISWANATH, P. **Fundamentals of Wireless Communication**. USA: Cambridge University Press, 2005. ISBN 0521845270.

WANG, F. Pilot-based channel estimation in ofdm system. In: . [s.n.], 2011. Disponible em: <<https://api.semanticscholar.org/CorpusID:13874737>>.

WEINSTEIN, S. B. The history of orthogonal frequency-division multiplexing [history of communications]. **IEEE Communications Magazine**, v. 47, n. 11, p. 26–35, 2009.

WIDROW B.; HOFF, M. E. Adaptive switching circuits. **IRE WESCON CONVENTION RECORD, Aug. 1960, Los Angeles, USA. Proceedings [...]**, 1960.

WOLNIANSKY, P. W. V-blast: An architecture for realizing very high data rates over the rich-scattering wireless channel. **URSI Int. Symp. on Signals, Systems and Electronics**, p. 295–300, 1998.

YANG, Y. et al. Deep learning-based channel estimation for doubly selective fading channels. **IEEE Access**, v. 7, p. 36579–36589, 2019.

YE, H.; LI, G. Y.; JUANG, B. H. Power of deep learning for channel estimation and signal detection in ofdm systems. **IEEE Wireless Communications Letters**, vol. 7, no. 1, pp. 114117, 2018.

ZHANG, W.; GAO, F.; YIN, Q. Blind channel estimation for mimo-ofdm systems with low order signal constellation. **IEEE Communications Letters**, v. 19, n. 3, p. 499–502, 2015.

NUP: 23081.072237/2024-11

Prioridade: Normal

Homologação de ata de defesa de TCC e estágio de graduação  
125.322 - Bancas examinadoras de TCC: indicação e atuação

### COMPONENTE

Ordem	Descrição	Nome do arquivo
6	TCC versão final	TCC_emanuel _versão_final.pdf

### Assinaturas

11/07/2024 08:44:43

SAMUEL TUMELERO VALDUGA (PROFESSOR DO MAGISTÉRIO SUPERIOR (Ativo))  
07.38.00.00.0.0 - DEPARTAMENTO DE ELETRÔNICA E COMPUTAÇÃO - DELC



Código Verificador: 4317940

Código CRC: 957e5ec3

Consulte em: <https://portal.ufsm.br/documentos/publico/autenticacao/assinaturas.html>

