

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HUGO ALEXANDRE OLIVEIRA DA CRUZ

**METODOLOGIA DE PREDIÇÃO DE PERDA DE PROPAGAÇÃO E
QUALIDADE DE VÍDEO EM REDES SEM FIO INDOOR POR MEIO
DE REDES NEURAS ARTIFICIAIS**

DM 09/2018

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**METODOLOGIA DE PREDIÇÃO DE PERDA DE PROPAGAÇÃO E
QUALIDADE DE VÍDEO EM REDES SEM FIO INDOOR POR MEIO
DE REDES NEURAIS ARTIFICIAIS**

HUGO ALEXANDRE OLIVEIRA DA CRUZ

DM 09/2018

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HUGO ALEXANDRE OLIVEIRA DA CRUZ

**METODOLOGIA DE PREDIÇÃO DE PERDA DE PROPAGAÇÃO E
QUALIDADE DE VÍDEO EM REDES SEM FIO INDOOR POR MEIO
DE REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, do Instituto de Tecnologia da Universidade Federal do Pará, como parte dos requisitos para obtenção do grau de Mestre em Engenharia Elétrica na área de Telecomunicações.

Orientador: Prof. Dr. Gervásio Protásio dos Santos Cavalcante
Coorientador: Prof. Dr. Herminio Simões Gomes

DM 09/2018

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

- C955m Cruz, Hugo Alexandre Oliveira da
METODOLOGIA DE PREDIÇÃO DE PERDA DE PROPAGAÇÃO E QUALIDADE DE VÍDEO
EM REDES SEM FIO INDOOR POR MEIO DE REDES NEURAIS ARTIFICIAIS / Hugo Alexandre
Oliveira da Cruz. — 2018
95 f. : il. color
- Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica (PPGEE),
Instituto de Tecnologia, Universidade Federal do Pará, Belém, 2018.
Orientação: Prof. Dr. Gervásio Protásio dos Santos Cavalcante
Coorientação: Prof. Dr. Herminio Simões Gomes.
1. Vídeo digital. 2. Qualidade de vídeo. 3. Redes sem fio. 4. Redes neurais artificiais. I.
Cavalcante, Gervásio Protásio dos Santos, orient. II. Título
-

CDD 621.3811

**“METODOLOGIA DE PREDIÇÃO DE PERDA DE PROPAGAÇÃO E QUALIDADE
DE VÍDEO EM REDES SEM FIO INDOOR POR MEIO DE REDES NEURAIAS
ARTIFICIAIS”**

AUTORA: HUGO ALEXANDRE OLIVEIRA DA CRUZ

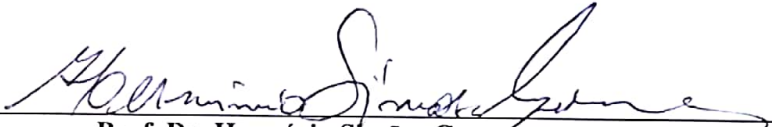
DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO
COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO
JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA
ELÉTRICA NA ÁREA DE TELECOMUNICAÇÕES.

APROVADA EM: 27/02/2018

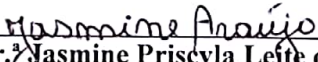
BANCA EXAMINADORA:



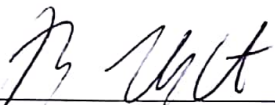
Prof. Dr. Gervásio Protásio dos Santos Cavalcante
(Orientador – PPGEE/UFPA)



Prof. Dr. Hermínio Simões Gomes
(Co-Orientador – ICEN/UFPA)



Prof.ª Dr.ª Jasmine Priscyla Leite de Araújo
(Avaliadora Interna – PPGEE/UFPA)



Prof. Dr. Bruno Souza Lyra Castro
(Avaliador Externo ao Programa – UFPA/Castanhal)

VISTO:

Prof.ª Dr.ª Maria Emília de Lima Tostes
(Coordenadora do PPGEE/ITEC/UFPA)

AGRADECIMENTOS

Aos meus pais Alberto Pereira da Cruz e Denice Oliveira da Cruz, pela educação, criação, amor e por todo o suporte necessário em todos os momentos da minha vida.

À minha irmã Mayara Alexandra Oliveira da Cruz, pelo amor e carinho, estando sempre presente em todas as situações.

E a todos os demais membros da minha família (avós, tios, tias, primos), pelo apoio e compreensão ao longo dos anos, contribuindo na formação do meu caráter, que, de uma forma indireta, contribuíram na realização desse trabalho.

Gostaria também de agradecer aos meus amigos, pelo bom convívio e suporte, especialmente a Andrey Silva, Ingrid Ariel e Waldiney Barros.

Ao professor Gervásio Cavalcante, por sua confiança, motivação e liderança, permitindo com sua grande experiência a orientação deste trabalho.

Ao meu coorientador, professor Herminio Simões Gomes, pela confiança e coorientação, tornando possível a produção deste trabalho.

Ao Laboratório de Computação e Telecomunicações (LCT) e seus integrantes, pela infraestrutura e ajuda prestada, tornando possível este trabalho.

Aos professores da Programa De Pós-graduação Em Engenharia Elétrica (PPGEE / UFPA) que com os seus ensinamentos contribuíram para a realização deste trabalho.

A Universidade Federal do Pará, pela oportunidade dada a mim para a realização desse trabalho.

A todos, meu sincero obrigado.

Hugo Alexandre Oliveira da Cruz

Sumário

1	INTRODUÇÃO	1
1.1	Trabalhos Correlatos.....	2
1.2	Motivação.....	3
1.3	Objetivo Geral	3
1.4	Objetivos Específicos e Contribuições	4
1.5	Organização da Dissertação	5
2	REDES DE COMUNICAÇÃO DE DADOS	6
2.1	Considerações iniciais.....	6
2.2	Definição de redes de comunicação de dados.....	6
2.3	História das redes de comunicação de dados.....	6
2.4	Modelos de Camadas OSI	7
2.5	Classificação das Redes Quanto à Extensão Física	9
2.6	IEEE 802.11 (WLAN)	11
2.7	Padrão IEEE 802.11ac.....	13
2.8	Considerações finais.....	15
3	IMAGEM E VÍDEO DIGITAL	16
3.1	Considerações Iniciais	16
3.2	Formato de Pixels	16
3.2.1	Formato RGB.....	16
3.2.2	Formato YUV	17
3.3	Amostragem e Quantização	18
3.4	Vídeo Digital.....	19
3.5	CODEC DE VÍDEO	19
3.5.1	CODECs sem Perdas.....	20
3.5.2	CODEC com Perdas.....	20

3.6	Avaliação de qualidade de vídeo	21
3.6.1	Métricas de QoE (Qualidade de Experiência):.....	22
3.6.2	PSNR (Peak Signal Noise Ratio).....	22
3.6.3	SSIM (Structural Similarity Index)	24
3.6.4	VQM (Vídeo Quality Metric).....	24
3.6.5	Melhores valores para cada métrica de QoE.....	25
3.7	Considerações finais	25
4	REDES NEURAIS ARTIFICIAIS (RNA)	26
4.1	Considerações Iniciais	26
4.2	Resumo histórico das RNAs	26
4.3	Introdução as RNAs	28
4.4	Neurônio Artificial	29
4.4.1	Funções de ativação.....	31
4.5	Arquiteturas das RNAs.....	35
4.5.1	Feedforward de camada simples.....	36
4.5.2	Feedforward de camada múltiplas.....	37
4.5.3	Recorrente ou realimentada	37
4.5.4	Reticulada.....	38
4.6	Processo de treinamento	39
4.6.1	Supervisionado	39
4.6.2	Não supervisionado	39
4.7	Redes Perceptron de Múltiplas Camadas (PMC).....	39
4.7.1	Descrição do algoritmo Backpropagation	41
4.7.2	Levenberg - Marquardt	46
4.7.3	Resilient - propagation.....	46
4.8	Validação Cruzada (como critério de parada antecipada).....	47
4.9	Aspecto de generalização da rede	47

4.10	Considerações finais.....	48
5	METODOLOGIA	49
5.1	Considerações iniciais	49
5.2	Campanha de medições	50
5.2.1	Ferramentas Utilizadas nas Medições.....	50
5.2.2	Cenário das Medições	53
5.2.3	Metodologia das Medições	54
5.2.4	Tratamentos de dados.....	55
5.3	Métodos de Predição Indoor	58
5.3.1	Métodos de predição para perda de PSNR (Descrição e Configuração das RNAs Utilizadas).....	58
5.3.2	Modelo de Predição de Perda de Propagação	68
5.4	Considerações finais.....	69
6	Análise e resultados.....	70
6.1	Considerações iniciais	70
6.2	Métodos de predição de perda de PSNR.....	71
6.2.1	1ª Abordagem.....	71
6.2.2	Sistema em cascata - 2ª abordagem.....	74
6.2.3	Comparação com modelo de qualidade de vídeo	86
6.3	Método de Predição de Perda de Propagação indoor.....	87
6.3.1	Comparação com modelo de perda de propagação.....	91
7	Conclusões e trabalhos futuros.....	93
7.1	Conclusões	93
7.2	Trabalhos Futuros	94
	Referências	95

Lista de Ilustração

Figura 1 - Classificação de redes de comunicação de dados quanto à sua extensão física.	9
Figura 2 - Representação do espaço amostral da paleta de cores RGB.	17
Figura 3 - Exemplo de plano de cor YUV $\alpha = 0,5$, representada na gama de cores RGB.	18
Figura 4 - Neurônio Artificial	29
Figura 5 - Representação gráfica da função de ativação Linear.	32
Figura 6 - a) Função sigmóide. b) influência do fator β na função de ativação sigmóide.	33
Figura 7 - a) Função tangente hiperbólica. b) influência do fator β na função de ativação tangente hiperbólica.	34
Figura 8 - Função de ativação gaussiana.	35
Figura 9 - Rede feedforward de uma única camada.	36
Figura 10 - Rede feedforward de múltiplas camadas.	37
Figura 11 - Rede recorrente.	38
Figura 12 - Rede com estrutura reticulada.	38
Figura 13 - Rede Perceptron de Múltiplas Camadas.	40
Figura 14 – Rede PMC, utilizada para ilustração da aplicação do método backpropagation.	41
Figura 15 - Processo de parada antecipada utilizando o método de validação cruzada.	47
Figura 16 – Fluxograma da metodologia empregada.	49
Figura 17 - Frames do vídeo Crowd Run com diferentes valores de PSNR. ...	51
Figura 18 – Tela do programa Acrylic.	52
Figura 19 - Esquema do cenário de medições.	53
Figura 20 – Equipamentos utilizados nas transmissões do vídeo.	54
Figura 21 - Software MATLAB.	56
Figura 22- Programa EvalVid em funcionamento e logs saída do mesmo.	57
Figura 23 - Rede PMC implementada.	59
Figura 24 - Progresso do erro de treinamento da RNA.	60

Figura 25 – Regressão dos dados gerados pela RNA e seus respectivos targets.	61
Figura 26 - Ilustração do Sistema de RNAs em cascata.	62
Figura 27 - Rede PMC, responsável por prever a potência do sinal recebido.	63
Figura 28 – Regressão dos conjuntos de dados da NET1.	64
Figura 29 - Rede PMC, responsável por prever a modulação.	64
Figura 30 - Regressão dos conjuntos de dados da NET2.	65
Figura 31 - Rede PMC, responsável por prever a taxa de transmissão.	66
Figura 32 - Regressão dos conjuntos de dados da NET3.	66
Figura 33 - Rede PMC, responsável por prever a perda de PSNR.	67
Figura 34 - Regressão dos conjuntos de dados da NET4.	68
Figura 35 – Comparação entre os valores de perda de PSNR medidos e preditos.	72
Figura 36 – Relação entre a Perda de PSNR, distância, número de paredes e potência do sinal.	73
Figura 37 – Estrutura da NET 1.	75
Figura 38 – Saída da NET 1.	75
Figura 39 - Estrutura da NET 2.	76
Figura 40 - Saída da NET2.	77
Figura 41 – Classificação da modulação utilizada na transmissão.	78
Figura 42 - Estrutura da NET 3.	78
Figura 43 - Saída da NET3.	79
Figura 44 – Classificação da taxa de transmissão do vídeo.	80
Figura 45 - Estrutura da NET 4.	81
Figura 46 – Saída da NET4.	81
Figura 47 – Saída do sistema em cascata.	83
Figura 48 – Comportamento do método de previsão de perda de PSNR proposto.	84
Figura 49 – Mapa de cobertura, baseado no método de previsão de perda de PSNR.	85
Figura 50 - Mapa da área de cobertura, com boa qualidade de vídeo.	85
Figura 51 – Comparação entre o método em cascata e o modelo Batalha para previsão de perda de PSNR.	87

Figura 52 – Saída da RNA, responsável pela predição de perda de propagação.	88
Figura 53 - Comportamento do método de predição de perda de propagação proposto.	89
Figura 54 - Mapa de cobertura, baseado no método de predição de perda de propagação.	90
Figura 55 - Mapa da área de cobertura, com boa qualidade de sinal.	90
Figura 56 - Comparação entre o método RNA e o modelo Batalha para predição de perda de propagação.	92

Lista de Tabelas

Tabela 1 - Modelo OSI	8
<i>Tabela 2 - Padrões 802.11 mais comuns, e suas características (Redes WLAN, 2017).</i>	12
Tabela 3 - Melhores valores esperados para cada métrica.....	25
Tabela 4 - Parâmetros aplicados no desenvolvimento das RNAs.....	58
Tabela 5 - Conjunto de treinamento.	59
Tabela 6: Perda média por parede.....	73
Tabela 7 - Relação entre PSNR e MOS.....	74
Tabela 8 - Mapa de modulações utilizadas.	77
Tabela 9 - Mapa de taxas de transmissão utilizadas.....	79
Tabela 10: Perda média por parede.....	92

Lista de abreviatura e siglas

4k 4096x2160 pixels

CODEC Codificador/Decodificador

IEEE Institute of Electrical and Electronics Engineers

ISM Industrial Scientific and Medical

ISO International Organization for Standardization

ITU-R International Telecommunication Union Radiocommunication Sector

LAN Local Area Network

MAN Metropolitan Area Network

Mean Burst Length (MBL)

MOS Mean Opinion Score

MPEG Moving Picture Experts Group

OSI Open systems interconnection

QoE Quality of Experience

QoS Quality of Service

RGB Red, Green and Blue

RNA Rede Neural Artificial

SNR Signal-to-Noise Ratio

UHD Ultra High Resolution

U-NII Unlicensed National Information Infrastructure

VCEG Video Coding Experts Group

Video Quality Model (VQM)

VoIP Voice over Internet Protocol

WAN Wide Area Network

Wi-Fi Wireless Fidelity

Wi-Fi Wireless-Fidelity

WLAN Wireless Local Area Network

Resumo

Esta dissertação apresenta uma metodologia que visa auxiliar o planejamento de sistemas de redes sem fio *indoor*, que requerem o conhecimento prévio dos ambientes nos quais serão implantados. Assim, é necessário precisão na análise do sinal por meio de uma abordagem empírica estatística, que leva em consideração alguns fatores que influenciam na propagação do sinal *indoor*: arquitetura dos prédios; disposição de móveis no interior dos compartimentos; números de paredes e pisos de diversos materiais, além do espalhamento das ondas de rádio. A metodologia adotada é baseada em medições com uma abordagem *cross-layer*, que demonstra o impacto da camada física em relação à camada de aplicação, com o objetivo de prever o comportamento da métrica de Qualidade de Experiência (QoE), chamada de *Peak signal-to-noise ratio* (PSNR), em transmissões de vídeo em 4k em redes sem fio 802.11ac, no ambiente indoor. Para tanto, foram realizadas medições, que demonstram como o sinal/vídeo se degrada no ambiente estudado, sendo possível modelar esta degradação por meio de uma técnica de inteligência computacional, chamada Redes Neurais Artificiais (RNA), na qual são inseridos parâmetros de entrada como, por exemplo, a distância do transmissor ao receptor e o número de paredes atravessadas a fim de prever perda de propagação e perda de PSNR. Para avaliar a capacidade de predição dos métodos propostos, foram obtidos os valores dos erros *Root Mean Square* (RMS) entre os dados medidos e os preditos, pelo os métodos de predição perda de propagação e perda de PSNR, sendo os valores respectivos 2,17 dB e 2,81 dB.

PALAVRAS-CHAVES: Vídeo, PSNR, Redes sem fio, RNA.

Abstract

This dissertation presents a methodology that aims to assist the planning of indoor wireless network systems, which require prior knowledge of the environments in which they will be deployed. Thus, accurate signal analysis is necessary by means of a statistical empirical approach, which takes into account some factors that influence the propagation of the indoor signal: architecture of the buildings; arrangement of furniture inside the compartments; numbers of walls and floors of various materials, and the spread of radio waves. The methodology adopted is based on measurements with a cross-layer approach, which demonstrates the impact of the physical layer in relation to the application layer, in order to predict the behavior of the Quality of Experience (QoE) metric, called Peak signal- to-noise ratio (PSNR), in 4K video streams on 802.11ac wireless networks in the indoor environment. In order to do so, measurements were performed, which demonstrate how the signal / video degrades in the studied environment. It is possible to model this degradation by means of a computational intelligence technique, called Artificial Neural Networks (RNA), in which input parameters are inserted as, for example, the distance from the transmitter to the receiver and the number of walls crossed in order to predict loss of propagation and loss of PSNR. In order to evaluate the predictive capacity of the proposed methods, the values of the Root Mean Square (RMS) errors between the measured and predicted data were obtained by the prediction methods loss of propagation and loss of PSNR, with respective values of 2.17 dB and 2.81 dB.

KEYWORDS: Video, PSNR, Wireless networks, ANN.

1 INTRODUÇÃO

Com a sanção do Marco Civil da Internet, em 23 de abril de 2014, que diz “o acesso à Internet é essencial ao exercício da cidadania” [Marco Civil, lei 12.965/14], ficou cada vez mais evidente a importância da internet na nossa sociedade. A partir dela, são fornecidos diversos serviços públicos e privados, relacionados com nossa rotina, crescendo, a cada dia, o número de pessoas que tem acesso à internet, seja residencial ou móvel, considerando a popularização dos *smartphones*.

Por meio da internet, somos capazes de receber diversas informações de forma simultânea, também sendo possível a interação e o debate com outras pessoas. A cada instante, ela fornece novas informações para as nossas vidas, seja no lazer, nas notícias ou academicamente, tornando-se, então, uma poderosa ferramenta de pesquisa. Assim, cabe ao usuário utilizá-la com sabedoria para o seu crescimento pessoal. Além disso, os serviços que têm um grande apelo popular, em geral, são as aplicações multimídia, como, por exemplo, vídeo e música streaming, VoIP (*Voice over Internet Protocol*), jogos *online* etc.

Aqui, vamos abordar, especificamente, a aplicação de streaming de vídeo, que é o objeto de estudo deste trabalho. O streaming de vídeo veio para facilitar o consumo de determinados tipos de conteúdo. Tomemos como exemplo um conteúdo que antes levava horas para ser transferido ao computador do usuário final e só então poderia ser assistido e que, agora, pode ser acessado instantaneamente, com altíssimas resoluções (4k), com várias opções de linguagens. Hoje, esses materiais são cada vez mais populares na internet, por serem de fácil assimilação, e muito mais atrativos.

Com isso, cresce a necessidade de serviços banda larga devido à demanda por alta velocidade, mobilidade e serviços em qualquer lugar e a qualquer hora. Notamos, portanto, uma massificação do acesso às redes sem fio, que são essenciais para que a demanda seja atendida.

Neste trabalho, vamos nos concentrar no estudo da predição da qualidade de vídeo 4k em redes *indoors*, com padrão IEEE 802.11ac, por meio da utilização da técnica de inteligência computacional chamada Rede Neural Artificial (RNA).

1.1 Trabalhos Correlatos

Devido à crescente demanda por vídeo streaming nos últimos anos em nosso cotidiano, cada vez mais vem surgindo o interesse no estudo da avaliação de qualidade de vídeo para que o usuário possa ter uma excelente experiência ao assistir determinado conteúdo. Logo, há a necessidade de mais estudos que considerem o comportamento de métricas de avaliação da qualidade de vídeo. Sendo assim, nesta seção serão apresentadas pesquisas relacionadas à predição de qualidade de vídeo e que utilizam algum tipo de técnica de inteligência computacional.

Em (DANISH & et al., 2016) é apresentado um estudo para predição de *Mean Opinion Score* (MOS) em dispositivos portáteis nos quais foram utilizados 3 vídeos com cada um tendo a resolução de (960x540) com 25fps com codec h.264, como ferramenta de modelagem foi utilizada uma Randon Neural Network (RNN) em uma rede de computadores com canal de transmissão sem fio, tendo 4 parâmetros de *Quality of Service* (QoS) como entrada para predição do modelo: taxa de perda de pacotes; Parâmetro de quantização do codificação; Quantidade de movimento no vídeo; Mean Burst Length (MBL), sendo o parâmetro de saída *Video Quality Model* (VQM) que, em seguida, foi mapeada para MOS. Como resultado, foi obtida uma ótima taxa de correlação R^2 0,90 e RMSE de 0,39 entre os dados medidos e os preditos.

Já em (Bashorun & et al., 2017), é realizada a predição do *Received Signal Strength Indicator* (RSSI), utilizando um Sistema *Neuro-Fuzzy*, tendo como parâmetros de entrada valores de *signal-to-noise ratio* (SNR) e distância em um ambiente indoor caracterizado como escritório. Nos resultados, é realizada uma comparação com os dados medidos e o modelo de predição de potência *Chipcon Empirical*, e os valores de erro RMS respectivamente são 0,353 e 2,822.

Por sua vez, no trabalho de (M. Alreshoodi, 2015), o objetivo principal do estudo é apresentar um modelo híbrido de predição qualidade de vídeo (4k /

UHD codificado com H.265) sem referência, em redes de computadores sem fio. Então, foi executada uma investigação do impacto dos parâmetros de Qualidade de Serviço (QoS) e dos parâmetros de codificação de 4 vídeos em um ambiente experimental, para serem inseridos como parâmetros de entrada no Sistema Neuro-Fuzzy. Assim, foi possível criar um sistema capaz de prever a métrica SSIM, que depois é mapeada para MOS. Como resultado, a taxa de correlação R^2 93,51% e RMSE de 0,17023 entre os dados medidos e os preditos.

1.2 Motivação

Considerando a importância das aplicações que envolvem tráfego de conteúdo multimídia em redes sem fio, sobretudo redes *Wireless Fidelity* (Wi-Fi), tornam-se necessários estudos que considerem o comportamento das métricas de avaliação da qualidade de vídeo, que são fundamentais, tanto para os usuários quanto para os projetistas e profissionais desses sistemas. Portanto, tais estudos podem ser alcançados por meio de uma metodologia que represente melhor os seguintes fatores: perda de propagação e os comportamentos das métricas de qualidade de serviços oferecidos pela rede e conseqüentemente a qualidade de experiência fornecida ao usuário.

1.3 Objetivo Geral

O objetivo geral deste trabalho é desenvolver uma metodologia capaz de auxiliar nos planejamentos de futuras redes de computadores, que levem em consideração a qualidade de experiência do usuário (QoE). Para tanto, é feita a análise do sinal transmitido, através de uma abordagem *cross-layer* (ARAÚJO, 2011), que demonstra o impacto da camada de física em relação à camada de aplicação. Assim, utiliza-se dados reais, obtidos a partir de uma campanha de medições, realizada em um ambiente específico (Salas de Aulas). Para modelagem, utiliza-se a técnica de inteligência computacional Redes Neurais Artificiais (RNA), a fim de prever a métrica de QoE, *Peak Signal Noise Ratio* (PSNR), em transmissões de vídeo em 4K em redes sem fio do padrão 802.11ac em ambiente indoor, tendo como parâmetros de entrada as métricas

potência recebida, taxa de transmissão, modulação, além das métricas que caracterizam o ambiente, como a distância entre transmissor e receptor e o número de paredes, pois ambos influenciam na qualidade do vídeo transmitido.

1.4 Objetivos Específicos e Contribuições

Os objetivos específicos deste trabalho são:

Desenvolver uma RNA, capaz de prever perda de PSNR tendo como parâmetro de entrada: distância entre transmissor e receptor; número de paredes; potência recebida; taxa de transmissão; modulação.

Desenvolver uma RNA em cascata, capaz de prever perda de PSNR tendo como parâmetro de entrada: distância entre transmissor e receptor; número de paredes.

Desenvolver uma RNA, capaz de prever perda de propagação tendo como parâmetro de entrada: distância entre transmissor e receptor; número de paredes e comparar os seus resultados com modelos de propagação existentes na literatura.

Gerar o mapa de cobertura da perda de PSNR e de propagação para o ambiente estudado.

As principais contribuições desta dissertação são:

Definir uma metodologia que poderá ser utilizada em outros ambientes e em outras frequências para predição de qualidade de vídeo.

Demonstrar o impacto da perda de propagação e da qualidade de vídeo com a distância e ao atravessar paredes, utilizando a frequência de 5.2 GHz.

Ser capaz de prever tanto a perda de propagação, quanto a perda de PSNR, utilizando o padrão IEEE 802.11ac, em um ambiente similar ao utilizados na pesquisa.

1.5 Organização da Dissertação

Este trabalho está dividido em sete capítulos que estão organizados da seguinte forma:

Capítulo 2: introdução referente às redes de computadores e ao seu histórico, explicando através de modelo em camadas, aprofundando-se na tecnologia WI-FI (*Wireless Fidelity*), a qual foi utilizado no desenvolvimento do trabalho.

Capítulo 3: trata sobre a imagem e vídeo digital e avaliação de qualidade do vídeo.

Capítulo 4: fundamentação teórica de redes neurais artificiais empregadas no desenvolvimento do trabalho.

Capítulo 5: apresentação da metodologia, que descreve os dados da campanha de medições, além do tratamento dos dados e as ferramentas que foram utilizadas.

Capítulo 6: apresentação dos resultados obtidos pelas RNAs desenvolvidas, demonstrando sua capacidade de predição e comparando-a com o modelo de perda de propagação e de perda de PSNR da literatura científica.

Capítulo 7: apresentação das considerações finais do autor e comentários dos possíveis trabalhos futuros a serem desenvolvidos.

2 REDES DE COMUNICAÇÃO DE DADOS

2.1 Considerações iniciais

Neste capítulo serão apresentados os fundamentos básicos de redes de comunicação de dados para o entendimento da dissertação, no qual serão mostrados os principais tipos de redes de comunicação de dados e padrões de rede sem fio, além de descrever detalhadamente o padrão IEEE 802.11ac, o qual será utilizado no trabalho.

2.2 Definição de redes de comunicação de dados

Uma rede de comunicação de dados é formada por um conjunto de máquinas capazes de trocar informações e partilhar recursos, interligados por um sistema de comunicação, podendo estes compartilharem recursos físicos e lógicos (MENDES, 2007).

2.3 História das redes de comunicação de dados

As redes de comunicação de dados surgiram da necessidade de comunicação entre máquinas calculadoras e computadores da época, realizada por usuários humanos através do carregamento de instruções entre os dispositivos. Em setembro de 1940, George Stibitz usou uma máquina de teletipo para enviar instruções para um conjunto de problemas a partir de seu *Model K* na Faculdade de Dartmouth, em Nova Hampshire, para a sua calculadora em Nova Iorque, e recebeu os resultados de volta pelo mesmo meio. Esta conexão de sistemas de saída como teletipos a computadores era um interesse na *Advanced Research Projects Agency* (ARPA) quando, em 1962, J. C. R. Licklider foi contratado e desenvolveu um grupo de trabalho o qual ele chamou de a "Rede Intergaláctica", um precursor da ARPANET (MENDES, 2007).

Em 1964, pesquisadores de Dartmouth criaram um sistema de compartilhamento de tempo de Dartmouth para usuários distribuídos de grandes sistemas de computadores. No mesmo ano, no M.I.T., um grupo de pesquisa apoiado pela General Electric e Bell Labs usou um computador (DEC's PDP-8) para rotear e gerenciar conexões telefônicas.

Durante a década de 1960, Leonard Kleinrock, Paul Baran e Donald Davies, de maneira independente, conceituaram e desenvolveram sistemas de redes os quais usavam datagramas ou pacotes, que podiam ser usados em uma rede de comutação de pacotes entre sistemas de computadores. Em 1969, a Universidade da Califórnia em Los Angeles, SRI (em Stanford), a Universidade da Califórnia em Santa Bárbara e a Universidade de Utah foram conectadas com o início da rede ARPANET usando circuitos de 50 kbits/s. (TANENBAUM, 2003)

As redes de comunicação de dados e as tecnologias necessárias para conexão e comunicação continuam a comandar as indústrias de *hardware* de computador, *software* e periféricos. Atualmente, redes de comunicação de dados constituem o núcleo da comunicação moderna, visto que o escopo da comunicação cresceu significativamente a partir da década de 1990, expansão que foi motivada pelo crescimento nos números e tipos de usuários de redes, desde o pesquisador até o usuário doméstico (TANENBAUM, 2003).

2.4 Modelos de Camadas OSI

O modelo de referência *Open systems interconnection* (OSI) foi desenvolvido pela *International Organization for Standardization* (ISO) como um modelo para a arquitetura de um protocolo de comunicação de dados entre computadores. Esta arquitetura é um modelo que divide as redes de comunicação de dados em 7 camadas hierárquicas como exibido na *Tabela 1*, de forma a se obter camadas de abstração. Cada protocolo implementa uma funcionalidade assinalada a uma determinada camada (TANENBAUM, 2003).

Tabela 1 - Modelo OSI


Camada (Layer)		Função
7	Aplicação <i>(Application)</i>	Corresponde às aplicações (programas) no topo da camada OSI, que serão utilizadas para promover uma interação entre a máquina-usuário (máquina destinatária e o usuário da aplicação). Esta camada também disponibiliza os recursos (protocolos) para que tal comunicação aconteça, por exemplo: HTTP, SMTP, FTP, SSH, POP3, IMAP, BitTorrent, DNS, Ping, etc.
6	Apresentação <i>(Presentation)</i>	Realiza a troca de dados e a comunicação entre <i>hosts</i> . A camada de Sessão permite que duas aplicações em computadores diferentes estabeleçam uma comunicação, definindo como será feita a transmissão de dados, pondo marcações nos dados que serão transmitidos.
5	Sessão <i>(Session)</i>	Responsável pela estrutura de controle para a comunicação entre as aplicações. Estabelece, gerencia e termina conexões (sessões) entre aplicações.
4	Transporte <i>(Transport)</i>	Responsável pela transferência de dados entre dois pontos de forma transparente e confiável com funções como controle de fluxo e correção de erro fim a fim.
3	Rede <i>(Network)</i>	Realiza o roteamento de funções, e também pode realizar a fragmentação e remontagem e os erros de entrega de relatório. Roteadores operam nesta camada, enviando dados em toda a rede estendida e tornando a Internet possível. Este é um esquema de endereçamento lógico - os valores são escolhidos pelo engenheiro de rede.
2	Enlace de dados <i>(Data Link)</i>	Detecta e, opcionalmente, corrige erros que possam acontecer no nível físico. É responsável por controlar o fluxo (recepção, delimitação e transmissão de quadros) e estabelece um protocolo de comunicação entre sistemas diretamente conectados.

1	Física (Physical)	Define especificações elétricas e físicas dos dispositivos. Em especial, define a relação entre um dispositivo e um meio de transmissão, tal como um cabo de cobre ou um cabo de fibra óptica. Isto inclui o layout de pinos, tensões, impedância da linha, especificações do cabo, temporização, hubs, repetidores, adaptadores de rede, e muito mais. A camada física é responsável por definir se a transmissão e à recepção do fluxo de bits brutos não-estruturados em um meio físico.
----------	------------------------------	---

2.5 Classificação das Redes Quanto à Extensão Física

Do ponto de vista da informática, uma rede de comunicação de dados consiste em diversos computadores que estão interligados e compartilham recursos entre si. Antes, estas redes existiam principalmente dentro de escritórios (rede local), mas, com o decorrer do tempo, tornou-se necessário trocar informações entre estes módulos de processamento, originando diversos outros tipos de rede, que serão descritas brevemente, como mostra a (TANENBAUM, 2003):

Figura 1 - Classificação de redes de comunicação de dados quanto à sua extensão física.



Fonte: (Wikispaces, 2017).

- **WAN (*Wide Area Network*)**

É uma rede de longa distância, que abrange uma área como um país ou até mesmo um continente (TANENBAUM, 2003).

- **MAN (*Metropolitan Area Network*)**

É uma rede metropolitana, que conecta diversas Redes Locais dentro de algumas dezenas de quilômetros, cuja área de abrangência corresponde a, no máximo, uma cidade (TANENBAUM, 2003).

- **LAN (*Local Area Network*)**

Redes Locais são capazes de interligarem dispositivos presentes dentro de um mesmo espaço físico, o que pode acontecer dentro de uma empresa, escola ou casa, sendo possível a troca de informações e recursos entre os dispositivos participantes (TANENBAUM, 2003).

- **WLAN (*Wireless Local Area Network*)**

É uma rede local sem fio que usa ondas de rádio para transmissão de dados e para conexão à Internet, sem necessidade de usar os tradicionais cabos para conectar dispositivos.

Inicialmente, os equipamentos para uma WLAN eram muito caros, por isso, eram usados somente em grandes corporações. Com a diminuição dos custos dos equipamentos, ocorreu a popularização desta tecnologia para a sociedade.

Além disso, uma das tecnologias usadas pela WLAN é o padrão de transmissão Wi-Fi, que permite a ligação de notebooks, smartphones, tablets, etc., desde que não estejam muito distantes do ponto de acesso.

Acerca dos tipos de redes de comunicação de dados que mencionamos, iremos aprofundar o estudo da rede WLAN, que está em foco neste trabalho (TANENBAUM, 2003).

2.6 IEEE 802.11 (WLAN)

As WLANs possibilitam conexão de uma rede de comunicação de dados por meio de ondas de rádio frequência (RF), nas quais as faixas de frequência de ondas de rádios utilizadas nestas redes são alocadas pela *International Telecommunication Union Radiocommunication Sector (ITU-R)*, que concede as faixas de frequência de 900 MHz, 2,4 GHz e 5 GHz como faixas de frequência licenciadas para comunicações, para fins domésticos, entre outros (Redes WLAN, 2017).

As redes locais sem fio são baseadas no modelo padrão 802.11, regido pelo *Institute of Electrical and Electronics Engineers (IEEE)*, comitê que define como as frequências de rádio são utilizadas na camada física e na subcamada MAC de *links* sem fio (Redes WLAN, 2017). Destacamos os padrões de redes locais sem fio mais utilizados:

- IEEE 802.11b (11 Mbps com 2.4 GHz)
- IEEE 802.11a (54 Mbps com 5.2 GHz)
- IEEE 802.11g (54 Mbps com 2.4 GHz)
- IEEE 802.11n (de 144 até 600Mbps com 2.4 e 5GHz)
- IEEE 802.11ac (de 87.6 Mbps até 866.7 Mbps com 5GHz)

Quanto à alocação de banda para as WLANs, as normas abrangem 83,5 MHz de largura de banda do espectro não licenciado para o *Industrial Scientific and Medical (ISM)* com a faixa de 2,4GHz e de 300MHz de largura de banda para o *Unlicensed National Information Infrastructure (U-NII)* com a faixa 5 GHz. Sendo assim, temos (Redes WLAN, 2017).

- ISM: 2.4GHz - 2.4835GHz
- U-NII: 5.150GHz - 5.250GHz (*indoor*), 5.250 GHz - 5.350 GHz (*in/outdoor*), e 5.725GHz - 5.825 GHz (*outdoor point-to-point*)

A Tabela 2 mostra as especificações dos cinco padrões citados anteriormente, a fim de compará-los:

Tabela 2 - Padrões 802.11 mais comuns, e suas características (Redes WLAN, 2017).

Padrão	802.11b	802.11a	802.11g	802.11n	802.11ac
Frequência	2400 – 2483.5 GHz (2.4GHz)	5150 – 5250 GHz 5250 – 5350 GHz 5725 – 5825 GHz (5.7 GHz)	2400 – 2483 GHz (2.4) GHz	2.4 GHz e 5GHz	5Ghz
Banda	ISM	UNII	ISM	ISM, UNII	UNII
Alocação	83.5 MHz	300 MHz	83.5 MHz	83.5 MHz e 300 MHz	300 MHz
Número de canais não subpostos	3	12	3	3/12	12
Largura do canal	20 MHz	20 MHz	20 MHz	20, 40 MHz	20, 40, 80,160 Mhz
Taxa Max. De transmissão	11 Mbps	54 Mbps	54 Mbps	144 à 600 Mbps	293 à 6992,6 Mbps
MAC	CSMA/CA	CSMA/CA	CSMA/CA	CSMA/CA	CSMA/CA
Modulação	DSSS	OFDM	OFDM DSSS	OFDM/OFDMA com MIMO	OFDM/256-QAM com MU-MIMO

As redes sem fio apresentam as seguintes vantagens (Redes WLAN, 2017) :

- Flexibilidade: dentro da área de cobertura, dois dispositivos podem se comunicar sem restrições físicas. Sendo assim, permite que a rede alcance lugares onde os fios não poderiam chegar.

- **Facilidade:** é de fácil instalação se comparado com uma rede cabeada, pois evita a passagem de cabos através de paredes, canaletas e forros. Portanto, há o uso mais eficiente do espaço físico.
- **Diversas topologias:** pode-se utilizar diversas topologias a fim de atender um objetivo específico, devido ao fato das configurações de topologia serem facilmente alteradas em relação as redes cabeadas, o que provoca maior facilidade de expansão e manutenção reduzida.

Em contrapartida, possuem as seguintes desvantagens (Redes WLAN, 2017):

- **Qualidade de serviço:** a qualidade do serviço provido ainda é menor que a das redes cabeadas, visto que há uma pequena banda passante devido às limitações da rádio transmissão e a alta taxa de erro devido à interferência.
- **Segurança:** os canais sem fio são mais suscetíveis, aos interceptores não desejados e interferência de outros equipamentos, que trabalhem na mesma faixa de frequência e também equipamentos elétricos, acarretando em perdas de dados e alta taxa de erros na transmissão.
- **Baixa transferência de dados:** embora a taxa de transmissão das redes sem fio cresça rapidamente, ela ainda é inferior se comparada com as redes cabeadas, apesar de atenderem satisfatoriamente à maioria da demanda das aplicações atuais.

Neste trabalho, utilizaremos o padrão 802.11ac, pois é um padrão capaz de suportar altas taxas de transmissão.

2.7 Padrão IEEE 802.11ac

O IEEE 802.11ac é um padrão de rede sem fio da família 802.11 (que é comercializado sob o nome da marca Wi-Fi), desenvolvido na IEEE Standards Association, fornecendo redes de área local sem fio (WLAN) de alto rendimento na banda de 5 GHz. O padrão foi desenvolvido a partir de 2008 até 2013 e

publicado em dezembro de 2013 (ANSI aprovado em 2013-12-11), (Redes WLAN, 2017).

As redes sem fio estão aumentando a velocidade de maneira exponencial, tornando-se, cada vez mais, o principal mecanismo de acesso à internet. O padrão 802.11ac veio para suprir a necessidade de utilização massiva da rede Wi-Fi no mundo com a popularização de tablets e smartphones, já que utiliza múltiplas conexões de alta velocidade para transferir conteúdo e conversa simultaneamente com diversos aparelhos conectados ao roteador sem qualquer interrupção. Seus principais pontos de evolução são:

- O padrão IEEE 802.11ac funciona na frequência de 5GHz sendo dotado de canais adaptativos para a redução da interferência entre canais com uma maior largura de 80 ou 160MHz, o que possibilita utilização de modulações mais sofisticadas como 256QAM, na qual é possível a transmissão de 8 bits invés de 6 bits do padrão anterior 802.11n, o que resulta no aumento de símbolos transmitidos, por consequência no aumento da taxa de transmissão.
- Uma outra grande evolução do padrão é passar de quatro spatial streams (fluxo espacial) do padrão N para até oito “spatial streams”. Quanto mais spatial streams utilizados simultaneamente, maior a velocidade de transmissão, o que possibilita a utilização do Multi-User Mimo o que torna capaz que vários usuários transmitam dados para mais do que um receptor simultaneamente, outra sofisticação agregada ao padrão é o chamado *Beamforming*, trata-se de uma maneira de direcionar o sinal para o cliente aumentando a potência em sua direção. Com a padronização, apenas de uma forma de beamforming (“explicit feedback”), fica a critério de cada fabricante cada fabricante adotar sua técnica de *beamforming*. Tudo isso faz com que haja um aumento significativo na largura de banda e taxa de transmissão do padrão 802.11ac tornando-o mais eficaz e robusto.

2.8 Considerações finais

A cada implementação de um novo padrão, há a necessidade de novos projetos de rede sem fio, que devem ser bem planejados, com posicionamento correto dos *access points* para extrair o máximo de eficiência do padrão a ser implementado, levando em consideração as suas especificidades. Não basta apenas trocar os *access points* para o padrão 802.11ac. É necessário que toda a infraestrutura seja reavaliada. O padrão 802.11ac permitirá que dezenas de dispositivos possam estar conectados a um mesmo *Access point* e ainda usufruírem de velocidades de centenas de Mbps.

3 IMAGEM E VÍDEO DIGITAL

3.1 Considerações Iniciais

Este capítulo abordará conceitos teóricos importantes acerca do tema imagem e vídeo digital e avaliação de qualidade de vídeo, que são necessários para o entendimento desta dissertação.


3.2 Formato de Pixels

Ao visualizarmos uma imagem digital de perto, é possível notar-se pequenos quadrados coloridos nela, que, somados, formam o desenho completo. Esses pontos, que são a menor parte de uma imagem, levam o nome de *pixels*. A Cada *pixel* pode se atribuir uma cor, sendo que o conjunto de milhares de pixels formam a imagem por completa. Os dois formatos mais comuns para se representar um *pixel* são o formato RGB e YUV, que serão descritos a seguir (Filho & Neto, 1999).

3.2.1 Formato RGB

O RGB (*standard RGB*) é um sistema eletrônico de cores criado por duas empresas HP e Microsoft, desenvolvido para formar cores em um monitor. O formato de cor RGB é baseado nos três componentes de cores: vermelho (*Red*), verde (*Green*) e azul (*Blue*). O modelo de cores RGB, muito popular em processamento de imagens, descreve o espaço de cores com a composição de cores aditivas (sobreposição de cores), como mostra a Figura 2.

Figura 2 - Representação do espaço amostral da paleta de cores RGB.




Fonte: (Site Transcortec, 2017)

Cada componente de cor corresponde a certo comprimento de onda dentro do espectro de cores: vermelho 700nm, verde 546nm e azul 436nm. Os três componentes podem ser vistos como três vetores lineares independentes descrevendo um espaço de cor tridimensional, sendo que cada componente de cor é composta de 8 bits. Logo, um pixel com o formato RGB é composto por 8 bits x 3 componentes de cores = 24 bits. A origem deste espaço tridimensional está a cor preta RGB (0,0,0) e em outro extremo a cor branca RGB (255,255,255), sendo assim possível a formação de um espectro de cores de mais 16 milhões (16.777.216), variando de 0 a 255 (Filho & Neto, 1999).

3.2.2 Formato YUV

O formato YUV é um espaço de cor tipicamente utilizado para representar imagem colorida como mostra a Figura 3 responsável pela codificação da imagem colorida ou vídeo, considerando a percepção humana, de modo que permite uma largura de banda reduzida para componentes da cromaticidade. Dessa forma, permite que erros de transmissão ou perda de qualidade sejam despercebidos pela percepção humana em relação ao caso da representação RGB.

Figura 3 - Exemplo de plano de cor YUV $Y=0,5$, representada na gama de cores RGB.

Fonte: (Wikipedia, 2017).

O padrão YUV, anteriormente conhecido como YCrCb (Y Cr Cb), é um modelo de representação da cor dedicado à imagem e ao vídeo, que possui como base três componentes separadas: “Y”, que representa a luminância (luminosidade), isto é, a informação de preto e branco, enquanto U e V representam a crominância, ou seja, a informação sobre a cor (Filho & Neto, 1999).

3.3 Amostragem e Quantização

Cada imagem é constituída de *pixels*. Por sua vez, cada pixel é composto por um número x de *byte*. Por meio destes fatores, torna-se possível calcular o tamanho de uma imagem em *bytes*.

Dessa forma, o tamanho da imagem é dado em *pixels* (largura \times altura). Tomemos como exemplo uma imagem que possui 640×480 pixels, e cada pixel é caracterizado por 3 bytes que equivalem a 24 bit no padrão RGB, que são responsáveis por exprimir a cor de cada pixel. Assim, vemos que esta imagem tem o seguinte tamanho $640 \text{ pixels} \times 480 \text{ pixels} \times 3 \text{ bytes} = 921600 \text{ bytes}$, levando em consideração que o fluxo da imagem é mostrado a 30 quadros por segundo, isto é,

$921600\text{bytes} \times 30 \text{quadros} = 27648000 \text{bytes}$. Realizando a conversão para *Megabytes*, temos 27.648 MB por cada segundo de vídeo, sem levar em consideração o áudio.

Sendo assim, observamos que seria muito dispendiosa a transmissão de vídeos via um canal sem fio, devido à alta taxa de *bytes* que seria necessária. Portanto, devemos considerar que na transmissão sem fio há uma banda muito limitada, além de outros fatores (Filho & Neto, 1999).

A partir de tudo que foi exposto, surgiram maneiras de compactar e descompactar o vídeo transmitido, como veremos no próximo tópico.

3.4 Vídeo Digital

Um vídeo é uma sucessão de imagens ordenadas a um certo ritmo. O olho humano tem a capacidade de distinguir uma certa quantidade de imagens por segundo, fixando 24 imagens ou mais por segundo. Assim, torna-se possível enganar a informação transmitida pelo olho ao cérebro, dando a sensação de que estamos visualizando uma série suscetível de imagens, tornando-a um vídeo. Podemos caracterizar a fluidez de um vídeo pelo número de imagens por FPS (*Frames per second*. Em português, quadros por segundo) (Filho & Neto, 1999).

Outro fator relevante na exibição de um vídeo digital é a varredura de tela, que pode ser de dois tipos:

- Varredura progressiva (*Progressive Scan*): uma técnica utilizada para montar o conteúdo da tela, que "varre" a tela inteira em uma única passada, transmitindo e exibindo todas as linhas da tela a cada atualização.
- Varredura entrelaçada (*Interlaced*): este modo monta em cada passagem metade das linhas da tela, as linhas pares ou ímpares, formando a ilusão de uma resolução maior e transmitindo apenas metade da imagem formada (Filho & Neto, 1999).

3.5 CODEC DE VÍDEO

Um CODEC (Codificador/Decodificador) de vídeo é um algoritmo que operam removendo redundância temporal, espacial e/ou de frequência, que

permite comprimir e descomprimir vídeo, imagem e áudio digitais. Comumente, os algoritmos de compressão usados resultam em uma perda de informação. Entretanto, existem dois tipos de básicos de CODEC: os com perdas e os sem perdas. O problema que os CODEC pretendem resolver é a situação explicada anteriormente, em que a informação de um vídeo é muito grande em relação à capacidade de processamento e armazenamento que um computador é capaz de suportar, pois a manipulação deste vídeo como cópia, edição e visualização podem levar facilmente a exceder as possibilidades do computador ou levá-lo ao seu limite.

Em relação aos CODECs, devemos considerar alguns aspectos: o complexo equilíbrio entre a qualidade do vídeo e a quantidade de dados necessários para representá-lo, a complexidade dos algoritmos de codificação e decodificação, a robustez contra perda de dados e erros, entre outros fatores, para que seja possível escolher o melhor CODEC para cada situação.

3.5.1 CODECs sem Perdas

Os CODECs sem perdas codificam uma imagem para comprimir o arquivo sem alterar a imagem original. Logo, se o arquivo for descomprimido, o novo arquivo será idêntico ao original. Este tipo de CODEC normalmente gera arquivos codificados que são entre 50% a 75% vezes menores em relação aos arquivos originais (Filho & Neto, 1999).

3.5.2 CODEC com Perdas

Por sua vez, os CODEC com perdas codificam uma imagem gerando uma certa perda de qualidade, pois visam alcançar altas taxas de compressão, que são maiores que 90% em relação aos arquivos originais. Porém, esta perda de qualidade é balanceada com a taxa de compressão para que não sejam criados pixels defeituosos (Filho & Neto, 1999).

3.5.2.1 H.264 / MPEG-4

O MPEG-4 é um padrão que foi utilizado primeiramente para compressão de dados digitais de áudio e vídeo (AV). Introduzido no final de 1998, é a designação para um grupo de padrões de codificação de som e vídeo e tecnologia relacionada de acordo com a ISO/IEC *Moving Picture Experts Group* (MPEG). O formato permite a codificação de dados multimídia sob formas de objetos numéricos, visando à obtenção de mais interatividade, o que torna o seu uso particularmente adaptado à Web e aos dispositivos móveis.

O H.264 é o CODEC que utilizaremos neste trabalho, é um padrão para compressão de vídeo muito difundido, ele é baseado no MPEG-4 Part 10 ou AVC (*Advanced Video Coding*). O padrão foi desenvolvido pela ITU-T *Video Coding Experts Group* (VCEG) em conjunto com a ISO/IEC MPEG que formaram uma parceria conhecida por *Joint Video Team* (JVT). A versão final, formalmente chamada por ISO/IEC 14496-10, foi lançada em maio de 2003, H.264 tem como principais vantagens (Wiegand, Sullivan, Bjontegaard, & Luthra, 2003):

- Eficiência de codificação melhorada;
- Possibilidade de codificação de diferentes mídias (vídeo, áudio, fala);
- Flexibilidade a erros que tornam as transmissões robustas;
- Possibilidade de interação com a cena audiovisual gerada através do receptor.

3.6 Avaliação de qualidade de vídeo

Sabemos que a interferência no canal afeta diretamente a qualidade do tráfego de informação na rede, devido à utilização da transmissão de dados por meio de ondas eletromagnéticas. No caso de transmissão de vídeos, que são quadros contínuos e síncronos, faz-se necessário uma boa conexão para satisfazer o usuário final.

Sendo assim, a avaliação da qualidade de vídeo pode ser feita levando em consideração as métricas subjetivas, ou seja, baseadas na percepção humana, ou métricas objetivas, baseadas em modelos matemáticos para estimar

a média das opiniões dos usuários. Este trabalho avalia os vídeos por meio das métricas objetivas.

Nesse sentido, as métricas objetivas são divididas em três tipos, que variam de acordo com a disponibilidade do vídeo original, considerado livre de distorção ou de alta qualidade:

- FR (*Full Reference*) Referência completa (Z. Wang et al., 2003): quando o sinal de vídeo de referência não degradado está totalmente disponível;
- RR (*Reduced Reference*) Referência reduzida (Z. Wang et al., 2003): quando o sinal de vídeo original não é totalmente disponível;
- NR (*No-Reference*) Sem Referência (Tian & Zhu, 2009): quando as sequências de vídeo de referência não são acessíveis (avaliação cega).

O modelo de avaliação de vídeo utilizado no trabalho é do tipo FR, porque utilizamos duas entradas (vídeo original e vídeo degradado) para obter a qualidade de vídeo observada pelo usuário (observador). Desta maneira, é perceptível visualmente que aspectos de desempenho da rede afetem aspectos da qualidade de experiência do usuário.

3.6.1 Métricas de QoE (Qualidade de Experiência):

São utilizadas para medir a satisfação do usuário em relação à aplicação, com o objetivo de balancear a capacidade entre nível de experiência do usuário (usabilidade) e custo computacional (custo financeiro). A seguir, veremos algumas métricas QoE.

3.6.2 PSNR (Peak Signal Noise Ratio)

É um método objetivo de avaliação de qualidade de vídeos e imagens, sendo, atualmente, o mais difundido na comunidade científica. Esta métrica relaciona o nível máximo de potência de um sinal pelo nível de potência do ruído, quando comparamos um sinal antes e depois de um processo de degradação, e a unidade que a representa é o dB (decibel), (Z. Wang et al., 2003).

Existem diferentes abordagens para computar a PSNR de uma imagem. Sendo que para a abordagem do cálculo da PSNR para imagens em cores é necessário separa os canais Y-Cb-Cr, no qual Y é luminância. Devido ao fato, de o olho humano ser mais sensível à informação de luminância, a qual carrega informação a respeito da forma da imagem. Sendo assim, a abordagem empregada leva em consideração apenas o canal de luminância. A métrica PSNR foi a utilizada no trabalho como métrica de QoE sendo esta, representada pela Equação 1.

$$PSNR = 10 \log_{10} \frac{L^2}{MNT \sum_{m=1}^M \sum_{n=1}^N \sum_{t=1}^T [I(m,n,t) - \hat{I}(m,n,t)]^2} \quad (1)$$

Onde:

L : é a faixa dinâmica dos valores de pixel, para um sinal de 8 bits/pixel, L é igual a 255.

M e N : são a largura e a altura (resolução do vídeo) das sequências do vídeo original e do vídeo degradado respectivamente;

T : é o número de quadros que contém as sequências $I(m, n, t)$;

$\hat{I}(m, n, t)$: representam o pixel na posição (m, n) do quadro, t é o quadro da sequência original e degradada, respectivamente.

3.6.2.1 Perda de PSNR

A perda de PSNR é uma forma de generalizarmos a métrica PSNR, tendo em vista que ela é diferente para cada vídeo. No decorrer deste estudo, trabalharemos com a métrica perda de PSNR, que consiste em "PSNRmaxima" como a PSNR do vídeo original menos a "PSNRmedida" como o PSNR do vídeo transmitido (degradado), de acordo com a Equação 2.

$$Perda\ de\ PSNR = PSNR_{maxima} - PSNR_{medida} \quad (2)$$

3.6.3 SSIM (Structural Similarity Index)

É uma métrica que compara cada quadro das sequências de vídeo original e vídeo degradado para quantificar a degradação sofrida. Fundamenta-se na ideia de que imagens naturais são altamente estruturadas, isto é, seus pixels apresentam forte dependência, especialmente quando estão espacialmente próximos. Estas dependências carregam informações importantes sobre a estrutura dos objetos na cena. Logo, seu algoritmo tenta estimar a similaridade entre o vídeo original e o degradado (Z. Wang et al., 2003). O SSIM é regido pela Equação 3 mostrada a seguir:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (3)$$

Sendo x e y as dimensões de um quadro, e μ_x e μ_y as médias de x e y . E σ_x^2 e σ_y^2 são as variâncias de x e y respectivamente, σ_{xy} a covariância entre x e y , sendo c_1 e c_2 variáveis para estabilizar a divisão com denominador.

3.6.4 VQM (Vídeo Quality Metric)

A métrica objetiva de qualidade de vídeo VQM usa o vídeo original e o vídeo degradado como entradas para avaliar a qualidade de vídeo, com o intuito de prever as classificações subjetivas que seriam obtidas caso fossem feitas por meio das opiniões dos usuários (Z. Wang et al., 2003). Ela também mede os efeitos de percepção do vídeo (distorções de cor, distorção de pixel, ruído e nível de embaçamento do vídeo).

3.6.5 Melhores valores para cada métrica de QoE

Para termos uma noção mais precisa das métricas definidas anteriormente, a Tabela 3 mostra os melhores valores para cada métrica, além de sua unidade utilizada no trabalho.

Tabela 3 - Melhores valores esperados para cada métrica.

Métricas	Melhores Valores	Unidades
PSNR	Maior melhor	dB
Perda de PSNR	Menor Melhor	dB
VQM	Menor melhor	0 a 1
SSIM	Maior melhor	0 a 1

3.7 Considerações finais

Tendo definido o que é imagem e vídeo digital e como avaliar a qualidade destes através das métricas objetivas apresentadas. O trabalho propõe um estudo a respeito da transmissão de vídeo de *Ultra High Resolution* (UHD/4k) em redes sem fio do padrão 802.11ac, algo que se tornará mais comum com advento de dispositivos como televisões, smartphones que suportam esses tipos de tecnologia.

4 REDES NEURAS ARTIFICIAIS (RNA)

4.1 Considerações Iniciais

Neste capítulo, apresentamos a fundamentação teórica da técnica de inteligência computacional, chamada Rede Neural Artificial, utilizada no desenvolvimento do trabalho. As redes neurais são comumente empregadas em diversos problemas relacionados as engenharias e ciências. Neste trabalho, será aplicada como aproximador universal de funções, com o objetivo de mapear o relacionamento funcional entre as variáveis de um processo. Ao longo do capítulo, descreveremos a sua construção e aplicação.

4.2 Resumo histórico das RNAs

As Redes Neurais Artificiais surgiram em 1943, com o neurofisiologista Warren McCulloch e o matemático Walter Pitts, da Universidade de Illinois, que resolveram fazer uma analogia entre as células nervosas e o processo eletrônico, em um artigo publicado no *Bulletin of Mathematical Biophysics*, intitulado: Um cálculo lógico das idéias intrínsecas da atividade neural (“*A Logical Calculus of the Ideas Immanent in Nervous Activity*”), (Zambiasi, 2013).

Em 1949, o biólogo e psicólogo Donald Hebb, que estudava o comportamento dos animais, escreveu um livro chamado *The Organization of Behavior*, no qual propôs um princípio de aprendizado em sistemas nervosos complexos, ou seja, uma lei que descreve o funcionamento quantitativo da sinapse e do processo de treinamento humano, que ficou conhecida como aprendizagem hebbiana (Zambiasi, 2013).

Já em 1958, Frank Rosenblatt, na Universidade de Cornell, baseou-se nas linhas de pensamento de McCulloch para desenvolver o seu modelo matemático de sinapse humana. Este criou uma rede de múltiplos neurônios do tipo discriminadores lineares e a batizou de rede perceptron. Devido as suas

complexas pesquisas e inúmeras contribuições técnicas, muitos o consideram como fundador da neurocomputação.

No início da década de 1960, Widrow e Hoff publicam um artigo no qual especificam um neurônio artificial baseado no modelo de McCulloch e Pitts, denominado ADALINE, cuja importância está associada à regra de aprendizagem proposta, a regra Delta. Além de também propor uma combinação em série de ADELINES, que ficou conhecida como MADALINE (Multiple Adaline).

Em 1969, Minsky e Seymour Papert lançaram em uma obra chamada Perceptrons, a qual expôs as limitações do modelo de Rosenblatt, provando que tais redes não são capazes de resolver uma ampla classe de problemas devido às restrições de representação. O impacto desta publicação foi devastador, praticamente desaparecendo o interesse em redes neurais artificiais, visto que apenas poucos pesquisadores continuaram com seus estudos na área.

No início da década de 80, muitos pesquisadores publicaram inúmeras propostas para a exploração de desenvolvimento e pesquisa em redes neurais. O físico e biólogo de reputação mundial John Hopfield também se interessou pela neurocomputação e escreveu vários artigos em 1982, que levaram vários cientistas a se unirem nesta nova área emergente. Hopfield reascendeu as pesquisas em neurocomputação, criticando fortemente as teorias apresentadas por Minsky e Papert em 1969.

Este campo de pesquisa cresceu muito em 1986, quando o professor de psicologia da Universidade de Stanford, David E. Rumelhart, e seu colega James L. McClelland, professor de psicologia da Universidade de Carnegie Mellon, publicaram o livro *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* (vol.1: Foundations, vol.2: Psychological and Biological Models). Nesse livro, eles apresentam um modelo matemático e computacional que propicia o treinamento supervisionado dos neurônios artificiais. Surgia, então, o algoritmo backpropagation, um algoritmo de otimização global sem restrições (Zambiasi, 2013).

Em 1987 ocorreu a Primeira Conferência de Redes Neurais. Também foi formada a Sociedade Internacional de Redes Neurais (International Neural Networks Society - INNS) juntamente com o INNS Journal em 1989, do Neural Computation e do IEEE Transactions on Neural Networks em 1990.

4.3 Introdução as RNAs

A tecnologia das Redes Neurais Artificiais (RNA's) objetiva a resolução de problemas relacionados ao reconhecimento de padrões, que geralmente são baseados em um conjunto de dados previamente conhecido, modelando sistemas através de circuitos (conexões sinápticas), que possam simular o sistema nervoso humano, ou seja, processar informações.

As RNAs consistem em um grande número de unidades computacionais simples, chamadas de neurônios artificiais, interligados entre si por um grande número de interconexões, inspirados na estrutura e operação do sistema nervoso biológico humano. AS RNAs são representadas matematicamente por vetores/ matrizes de pesos sinápticos artificiais, que procuram reproduzir características humanas (aprendizado, associação, generalização e abstração, etc.).

Cada neurônio processa os sinais de entrada da rede, os quais são controlados por pesos sinápticos que se adaptam, durante o treinamento, por um algoritmo de aprendizado. Devido à sua estrutura, as Redes Neurais são bastante efetivas no aprendizado de padrões a partir de dados não-lineares, incompletos, com ruído e até compostos de exemplos contraditórios (HAYKIN, 2001).

Principais características das RNAs: (Silva, Spatti, & Flauzino, 2010)

Adaptação: A adaptação dos parâmetros internos da rede, tipicamente seus pesos sinápticos, são ajustados a partir da apresentação sucessiva de exemplos/amostras relacionados ao comportamento do processo a ser modelado.

Capacidade de aprendizado: por intermédio da aplicação de um método de treinamento, a rede consegue extrair o relacionamento existente entre as variáveis de entrada com as variáveis de saída.

Habilidade de Generalização: após o processo de treinamento da rede, essa é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções.


Organizações de Dados: a rede é capaz de realizar uma organização interna, com o intuito de agrupamento de padrões.

4.4 Neurônio Artificial

Os neurônios artificiais utilizados nos modelos de redes neurais artificiais são não-lineares, fornecem saídas tipicamente contínuas, e realizam funções simples, empregando uma função de ativação aos sinais de suas entradas, a fim de produzir uma resposta como saída (Silva, Spatti, & Flauzino, 2010).

O modelo de neurônio artificial mais simples, mostrado na Figura 4, foi baseado em estudos de geração e propagação de impulsos elétricos pela membrana celular, que engloba as principais características de uma rede neural biológica, isto é, o paralelismo e alta conectividade. Este modelo foi proposto por McCulloch e Pitts, em 1943, sendo ainda muito utilizado nas RNAs atuais (Silva, Spatti, & Flauzino, 2010).

Figura 4 - Neurônio Artificial



Fonte: (Silva; Spatti; Flauzino. 2010).

Baseado na ilustração acima, descreveremos os sete elementos básicos que constituem um neurônio artificial (Silva, Spatti, & Flauzino, 2010):

Sinais de entrada $\{X_1, X_2, \dots, X_n\}$

São sinais provenientes de meios externos, que representam valores assumidos pelas variáveis de uma aplicação.

Pesos Sinápticos $\{W_1, W_2, \dots, W_n\}$

São valores de ponderação das variáveis de entradas, tem como objetivo quantificar a relevância de cada entrada.

Combinador Linear $\{ \Sigma \}$

Sua função é agregar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação.

Limiar de Ativação $\{\theta\}$

É a variável responsável por especificar qual será o patamar apropriado para que o resultado do combinador linear possa gerar um valor de disparo em direção à saída do neurônio.

Potencial de Ativação $\{u\}$

É o resultado produzido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se o valor for positivo, tem um potencial excitatório, caso contrário, terá um potencial inibitório, calculado segundo a Equação 4.

$$u = \sum_{i=1}^n W_i \cdot X_i - \theta \quad (4)$$

Função de Ativação $\{g\}$

Seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional.

Sinal de Saída $\{y\}$

Consiste do valor final produzido pelo o neurônio em relação a um determinado conjunto de sinais de entrada, dado pela Equação 5.

$$y = g(u) \quad (5)$$

4.4.1 Funções de ativação

Há vários tipos de funções de ativação. Aqui, serão apresentadas funções de ativação totalmente diferenciáveis, pelo fato de terem a capacidade da não linearidade.


4.4.1.1 Função Linear

A função de ativação linear ou função identidade fornece resultados com saídas idênticas aos valores do potencial de ativação $\{u\}$, tendo sua expressão matemáticas definida pela Equação 6 (Silva, Spatti, & Flauzino, 2010):

$$g(u) = u \quad (6)$$

A Figura 5 mostra a representação gráfica da função linear.

Figura 5 - Representação gráfica da função de ativação Linear.




Fonte: (Silva, Spatti, & Flauzino, 2010).

4.4.1.2 Função Sigmóide ou Logística

O resultado da saída da função sigmóide assumirá sempre valores reais entre zero e um, tendo sua expressão matemática dada pela Equação 7:

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (7)$$

Onde β é uma constante real associada ao nível de inclinação da função sigmoide frente ao seu ponto de inflexão. A representação gráfica desta função é ilustrada na *Figura 6 a)*. Já o comportamento da função de ativação sigmóide em relação à variação do parâmetro de inclinação β é exibido na *Figura 6 b)* (Silva, Spatti, & Flauzino, 2010).

Figura 6 - a) Função sigmóide. b) influência do fator β na função de ativação sigmóide.

Fonte: (Silva, Spatti, & Flauzino, 2010).


4.4.1.3 Função Tangente Hiperbólica

O resultado da saída da função tangente hiperbólica, diferentemente da função sigmóide, sempre assumirá valores reais entre -1 e 1, cuja expressão matemática é definida pela Equação 8.

$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (8)$$

Onde β também está associado o nível de inclinação da função tangente hiperbólica em relação ao seu ponto de inflexão. A representação gráfica desta função é ilustrada na Figura 7 a), enquanto o comportamento da função de ativação tangente hiperbólica em relação à variação do parâmetro de inclinação β é exibido na Figura 7 b) (Silva, Spatti, & Flauzino, 2010).

Figura 7 - a) Função tangente hiperbólica. b) influência do fator β na função de ativação tangente hiperbólica.



Fonte: (Silva, Spatti, & Flauzino, 2010).


4.4.1.4 Função Gaussiana

Acerca da utilização da função de ativação gaussiana, a saída do neurônio produzirá resultados iguais para aqueles valores de potencial de ativação $\{u\}$, que estejam posicionados a uma mesma distância de seu centro (média), sendo que a curva é simétrica em relação a este. A Equação 9 da função gaussiana é dada por:

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (9)$$

Sendo c um parâmetro que define a média da função gaussiana e σ denota o desvio padrão associado a mesma. A Figura 8 mostra a representação gráfica da função de ativação gaussiana (Silva, Spatti, & Flauzino, 2010).

Figura 8 - Função de ativação gaussiana.



Fonte: (Silva, Spatti, & Flauzino, 2010).

4.5 Arquiteturas das RNAs

A arquitetura de uma RNA define a forma como os seus diversos neurônios estão arranjados ou dispostos, uns em relação aos outros. As redes podem ser classificadas quanto ao número de camadas (rede com uma única camada ou com múltiplas camadas) e ao tipo de conexões (*feedforward* ou *feedback*), que levam em consideração o direcionamento das conexões sinápticas dos neurônios.

Uma rede neural pode ter uma ou várias camadas. As redes que possuem uma única camada são as redes que possuem um nó entre uma entrada e uma saída da rede. Esse tipo de rede é indicado para a solução de problemas linearmente separáveis. Já as redes multicamadas possuem mais de uma camada entre as já existentes camadas de entrada e saída.

Basicamente uma rede neural pode ser dividida em três partes, denominadas de camadas:

- Camada de entrada

É responsável pelo recebimento dos sinais provenientes de meios externos, que representam valores assumidos pelas variáveis de uma aplicação.

- Camada escondida ou oculta

Esta camada é responsável por extrair o conhecimento implícito dos dados de entradas. Quase todo o processamento da rede é realizado nessa camada.

- Camada de saída


Esta camada é responsável pela produção e apresentação dos resultados finais da rede, os quais são advindos do processamento das camadas anteriores.

Nos tópicos seguintes serão explicitadas as principais arquiteturas utilizadas na constituição das RNAs.

4.5.1 Feedforward de camada simples

Esta arquitetura é definida como uma rede com a camada de entrada diretamente associada a um ou mais neurônios que vão gerar a resposta de saída como na Figura 9. Observe que o fluxo de dados segue sempre em direção à camada de saída. São empregadas em problemas de classificação de padrões e filtragem. Tipos: *Perceptron* e *Adaline* (Silva, Spatti, & Flauzino, 2010).

Figura 9 - Rede *feedforward* de uma única camada.

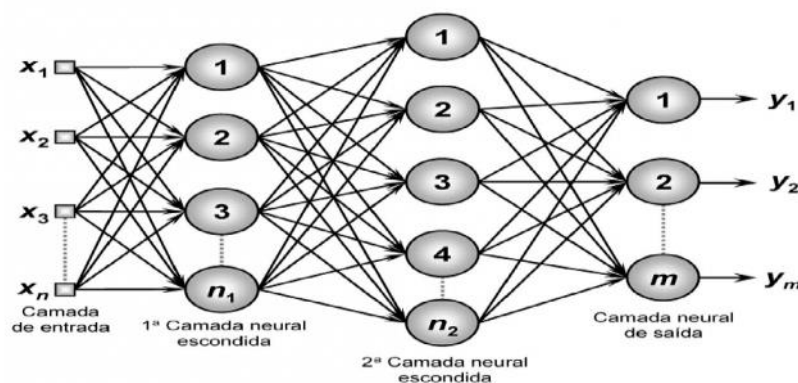


Fonte: (Silva, Spatti, & Flauzino, 2010).

4.5.2 Feedforward de camada múltiplas

Constituída por uma ou mais camadas escondidas de neurônios como mostra a Figura 10. São empregadas em problemas de aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos. Tipos: Perceptron Multicamadas, Redes de Base Radial (Silva, Spatti, & Flauzino, 2010).

Figura 10 - Rede feedforward de múltiplas camadas.




Fonte: (Silva, Spatti, & Flauzino, 2010).

4.5.3 Recorrente ou realimentada

Suas saídas são realimentadas como sinais de entrada para outros neurônios como pode ser visto na Figura 11, sendo assim empregadas para o processamento de sistemas variantes no tempo. São empregadas em previsões de séries temporais, otimização, identificação de sistemas e controle de processos. Tipos: Hopfield e Perceptron Multicamadas com Realimentação (Silva, Spatti, & Flauzino, 2010).

Figura 11 - Rede recorrente.




Fonte: (Silva, Spatti, & Flauzino, 2010).

4.5.4 Reticulada

Consideram a disposição espacial dos neurônios vistos na Figura 12 com o propósito da extração de características do sistema, ou seja, sua localização espacial serve para ajuste de seus pesos e limiares. São empregadas em problemas de agrupamento, reconhecimento de padrões, otimização de sistemas, etc. Tipo: Kohonen (Silva, Spatti, & Flauzino, 2010).

Figura 12 - Rede com estrutura reticulada.



Fonte: (Silva, Spatti, & Flauzino, 2010).

4.6 Processo de treinamento

Para que uma RNA atenda nossos objetivos, ela deverá ser treinada. O termo treinamento de uma rede neural consiste basicamente em fazê-la adotar valores de pesos e limiares.

4.6.1 Supervisionado

Deve-se dispor das amostras e das respectivas saídas desejadas para que os pesos e limiares sejam ajustados continuamente pelo algoritmo de aprendizagem, baseados em suas amostras de entrada, de modo que qualquer outra amostra futura apresentada a ela seja corretamente classificada. Logo, apresentaremos nossas amostras/dados na entrada da rede e direcionaremos uma resposta desejada fazendo com que a rede seja obrigada a modificar seus pesos e limiares. Assim, qualquer outro valor apresentado a ela depois que a rede estiver corretamente treinada, produzirá uma saída ou resultado igual ou próximo do desejado.

4.6.2 Não supervisionado


Neste processo de aprendizado não existe "professor". A rede tem de descobrir sozinha relações, padrões, regularidades ou categorias nos dados que lhe foram repassados e codificá-los como saídas. Seus pesos e limiares são ajustados pelo algoritmo de aprendizagem de modo a refletir os padrões extraídos do conjunto de dados.

4.7 Redes Perceptron de Múltiplas Camadas (PMC)

As redes perceptron de múltiplas camadas são caracterizadas pela presença de pelo menos uma camada intermediária (oculta) de neurônios, situada entre a camada de entrada e a respectiva camada de saída.

A arquitetura apresentada pelas redes PMCs são consideradas feedforward, pois os sinais das entradas serão propagados em direção à camada de saída. Logo, a saída dos neurônios da primeira camada representará a entrada dos neurônios da segunda camada e assim sucessivamente, como é exibido na Figura 13.

Figura 13 - Rede Perceptron de Múltiplas Camadas.



Fonte: (Silva, Spatti, & Flauzino, 2010).

As redes de múltiplas camadas surgiram a partir da existência de uma restrição das redes de uma única camada, sendo que esta restrição implica em afirmar que as redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias.


No entanto, o desenvolvimento do algoritmo de treinamento backpropagation, por Rumelhart, Hinton e Williams, em 1986, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado atualmente, ou seja, as redes Perceptron Multi-Camadas (PMC), treinadas com o algoritmo supervisionado, denominado backpropagation, também conhecido como regra delta generalizada.

4.7.1 Descrição do algoritmo Backpropagation

O algoritmo de treinamento *backpropagation* pode ser dividido essencialmente em duas fases. A primeira é denominada de “propagação adiante” ou *forward*, na qual os sinais de entradas $\{X_1, X_2, \dots, X_n\}$ do conjunto de treinamento são inseridos e são propagados camada a camada até a produção da respectiva saída. Portanto, essa fase visa obter valores atuais de pesos sinápticos e limiares de seus neurônios, possibilitando o cálculo do erro entre a saída da rede os valores de saídas desejadas.

A segunda fase do treinamento é chamada de “retro propagação” ou *backward*. Aqui, o erro calculado na fase anterior é propagado no sentido reverso, camada a camada, e, ao final deste processo, os pesos são ajustados de acordo com uma regra de correção de erro. A seguir, será detalhado o algoritmo de treinamento *backpropagation*, de acordo com a Figura 14.

Figura 14 – Rede PMC, utilizada para ilustração da aplicação do método *backpropagation*.



Fonte: (Network Types, 2017)

No exemplo da Figura 14, há a ilustração de uma rede PMC com três camadas, onde a camada de entrada (Input Layer) é formada pelo neurônio x_1 , x_2 , até o x_n . A camada escondida (Hidden Layer) pelo neurônio h_1 , h_2 , até o h_n . A camada de saída (Output Layer) pelo neurônio o_1 , o_2 , até o_n .

Levando em consideração uma rede com a seguinte topologia, na qual os neurônios da camada de entrada têm a função de ativação linear, enquanto os neurônios da camada oculta possuem função de ativação sigmóide e os neurônios das camadas de saída possuem função de ativação linear. O peso W_{ji} da camada oculta faz referência a conexão do neurônio i da camada escondida com a saída do neurônio j da camada de entrada.

4.7.1.1 Propagação adiante

4.7.1.2 Cálculo da saída da camada de entrada

De forma geral, para a saída do neurônio “n” da camada de entrada, temos que a saída é calculada pela Equação 10. Onde y_{In} é a saída do neurônio da camada de entrada (Input), x_n é a entrada “n” do padrão que esta sendo apresentado, w_n é o peso sináptico da conexão entre a entrada “n” e o neurônio “n” da camada de entrada e o B_{In} é o bias deste neurônio.

$$y_{In} = x_n \cdot w_n + B_{In} \quad (10)$$

4.7.1.2.1 Cálculo da Saída da camada escondida

Após ser calculada a saída dos neurônios da camada de entrada, eles são passados adiante para cada neurônio da camada escondida. Um neurônio “j” da camada escondida receberá N_i entradas (igual ao número de neurônios na camada de entrada) e sua saída será calculada em duas etapas, como segue:

4.7.1.2.2 Cálculo realizado no neurônio da camada escondida

A soma das entradas multiplicadas pelos pesos das respectivas conexões mais o valor do bias deste neurônio. Este processo para o neurônio j da camada de entrada está representado na Equação 11. Onde y_i é a saída do neurônio i da camada de entrada, $i=1,2, \dots, N_i$.

$$v_j = y_1 \cdot w_{j1} + y_2 \cdot w_{j2} + \dots + y_{N_i} \cdot w_{jN_i} + B_{hj} \quad (11)$$

Rearranjando a Equação 11, tornando-a mais geral temos a Equação 12:

$$v_j = \sum_{i=1}^{N_i} y_i \cdot w_{ji} + B_{hj} \quad (12)$$

4.7.1.2.3 Calculo da saída do Neurônio da camada escondida

A saída y_{hj} é calculada aplicando o valor v_j do neurônio j em uma das funções de ativação não lineares mencionada anteriormente. Como é visto na equação 13.

$$y_{hj} = g(v_j) \quad (13)$$

4.7.1.3 Calculo da camada de saída

As saídas dos neurônios da camada escondida são passadas para cada neurônio da camada de saída. Um neurônio “ j ” da camada de saída receberá N_h entradas (igual ao número de neurônios na camada escondida) e sua saída será calculada.

A saída do neurônio j da camada de saída é calculada pela Equação 14. Onde y_{oj} é a saída do neurônio da camada de saída (Output), y_{Hi} é a saída do neurônio i camada escondida (Hidden), w_{ji} é o peso sináptico da conexão entre

a saída do neurônio i e do neurônio j da camada de saída e o B_{Oj} é o bias deste neurônio.

$$y_{Oj} = y_{H1} \cdot w_{j1} + y_{H2} \cdot w_{j2} + \dots + y_{HNh} \cdot w_{jNh} + B_{Oj} \quad (14)$$

Rearranjando temos a equação 17:

$$y_{Oj} = \sum_{i=1}^{Nh} y_i \cdot w_{ji} + B_{Oj} \quad (15)$$

4.7.1.3.1 Cálculo dos erros

Cada neurônio j na camada de saída está associado a uma saída do padrão desejado, d_k , sendo assim é possível calcular o erro, e_j , para a saída de cada neurônio j pela fórmula da Equação 16. Onde n é o número do padrão que se está calculando a saída.

$$e_j(n) = d_j(n) - y_{Oj}(n) \quad (16)$$

4.7.1.4 Retropropagação (backward)

A computação para trás é utilizada para retro propagar o valor dos erros para as camadas mais internas da rede para serem utilizados no processo de atualização dos pesos sinápticos das camadas. Ela está definida basicamente em duas etapas: primeiramente, o cálculo dos gradientes locais dos neurônios; e, em seguida, a atualização dos pesos usando a regra delta generalizada.

4.7.1.5 Cálculo do Gradiente local dos Neurônios

A fórmula usada para o cálculo do gradiente de um Neurônio j de uma camada l é dada pela Equação 17.

$$\delta_j(n) = e_j(n) \cdot g'_j(v_j(n)) \quad (17)$$

Onde temos que:

n = número de entrada.

$v_j(n)$ = Valor da net para o padrão de entrada n .

$g'_j(v_j(n))$ = A derivada da função de ativação do neurônio j aplicada na net deste neurônio.

4.7.1.6 Camada de saída

Para calcular estes gradientes para a camada de saída que possui a função de ativação linear, utiliza-se a Equação 18, que deixa o gradiente do neurônio j em função do erro para o padrão apresentado.

$$\delta_j(n) = e_j(n) \quad (18)$$

4.7.1.7 Camada Escondida

Para calcular os gradientes para a camada escondida, a Equação 17 precisa ser adaptada, já que não se possui os valores dos erros na saída dos neurônios desta camada. Assim, é feita uma retropropagação dos erros na camada de saída para a camada oculta, a Equação 17 é adaptada na Equação 19.

$$\delta_j(n) = g'_j(v_j(n)) \cdot \sum_{k=1}^{N_o} \delta_k(n) \cdot w_{kj}(n) \quad (19)$$

Onde:

N_o = Número de neurônios na camada de saída.

k = neurônio k da camada de saída.

J = neurônio j da camada escondida.

4.7.1.8 Atualização dos Pesos dos Neurônios das camadas

A atualização dos pesos de um Neurônio j de uma camada l é realizada pela Equação (22).

$$W_{ji}(n + 1) = W_{ji}(n) + \eta \delta_j(n) \cdot y_i(n) \quad (22)$$

Onde:

W_{ji} = O peso sináptico da conexão entre o neurônio j da camada l .

η = A taxa de aprendizado.

y_i = A saída do Neurônio i da camada anterior.

4.7.2 Levenberg - Marquardt

É um método de otimização publicado primeiramente por Kenneth Levenberg em 1944 e aperfeiçoado por Donald Marquardt em 1963, baseado no método de Newton. Logo, este método se apresentou muito eficaz para otimização do algoritmo backpropagation, que faz com que a minimização não linear produza uma matriz Jacobiana esparsa, diminuindo de forma significativa a complexidade do algoritmo backpropagation, diminuindo o custo computacional na execução do mesmo (HAYKIN, 2001).

4.7.3 Resilient - propagation

O método *Resilient-propagation* é considerado uma otimização do algoritmo *back-propagation*, pois invés de considerar as variações de magnitude do gradiente da função erro, leva somente consideração a variação de seu sinal. Desta forma, a taxa de aprendizagem do método se torna dinâmica, pois quando os sinais do gradiente forem os mesmos, considerando interações sucessivas, significa que pode incrementar a taxa

de aprendizagem, caso contrário, significa que o ponto mínimo da função foi ultrapassado (Silva, Spatti, & Flauzino, 2010).


Com isso, é eliminado o problema das derivadas parciais do método *back-propagation*, as quais geram valores muito próximo de zero, o que resulta em um esforço computacional maior e na lentidão do processo de treinamento.

4.8 Validação Cruzada (como critério de parada antecipada)

A técnica de validação cruzada pode ser utilizada como parâmetro de parada do treinamento, a fim de evitar o overfitting da rede, podendo ser utilizada para identificar o começo do excesso de treinamento com o objetivo de manter a capacidade de generalização da rede.

Esta técnica consiste em checar o processo de aprendizagem a cada iteração do treinamento pela aplicação do subconjunto de validação, sendo o treinamento finalizado quando o erro quadrático começa a crescer, como ilustrado na Figura 15 (HAYKIN, 2001).

Figura 15 - Processo de parada antecipada utilizando o método de validação cruzada.



Fonte: Próprio autor.

4.9 Aspecto de generalização da rede

Pode-se considerar uma rede com uma boa capacidade de generalização quando o mapeamento da entrada com a saída da rede for aproximadamente correto, ou seja, a rede foi capaz de realizar uma boa interpolação sobre os dados de entrada, dados estes desconhecidos pela rede, pois não foram utilizados durante o processo de treinamento (HAYKIN, 2001).

4.10 Considerações finais

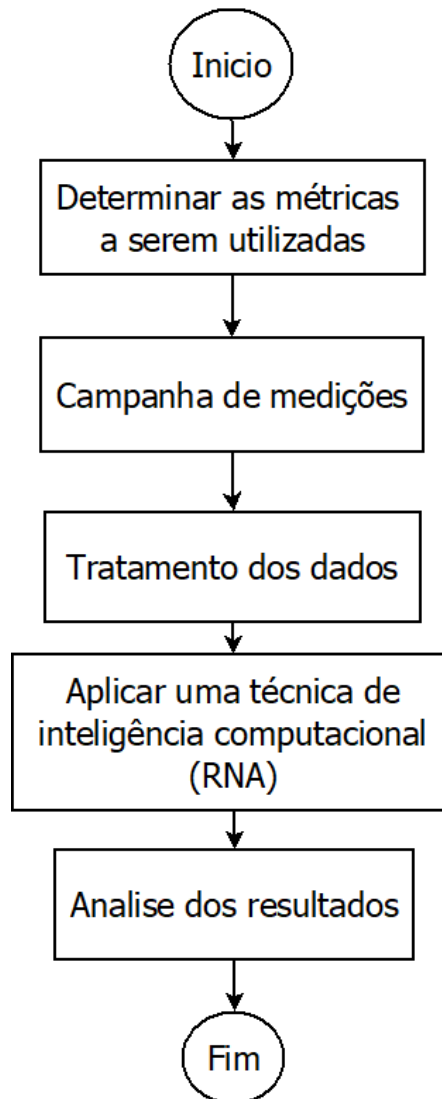
Este capítulo foi destinado a fundamentação teórica das RNAs, que foram utilizados neste trabalho com o intuito de modelar o comportamento das transmissões de vídeos em 4k em redes sem fio indoor, utilizando fatores como o tipo do ambiente e parâmetros da camada física da rede, somos capazes de realizar uma regressão nos dados obtidos através de medições, por meio das RNAs, sendo estas capazes de prever o comportamento das transmissões e a qualidade do vídeo transmitido. No capítulo seguinte será descrita as metodologias utilizadas no desenvolvimento desta pesquisa.

5 METODOLOGIA

5.1 Considerações iniciais

A metodologia aplicada neste trabalho é dividida nas seguintes fases: determinar as métricas relevantes para o desenvolvimento da pesquisa, campanha de medições, tratamento dos dados, implementação das RNAs, por fim, análise dos resultados, como é exibido na Figura 16.

Figura 16 – Fluxograma da metodologia empregada.



Fonte: Próprio autor.

Para o desenvolvimento deste trabalho, houve a necessidade de se obter dados referentes às medidas de uma rede de computadores real, ou seja, realizar medições que serão descritas neste capítulo. Tendo como objetivo verificar quais influências que o ambiente e a camada física exercem na qualidade da experiência prestada ao usuário, ao assistir um vídeo. Logo existiu a necessidade do tratamento destes dados obtidos, para implementações das RNAs, e a última etapa refere-se a análise dos resultados.

Para tanto, utilizou-se um conjunto de ferramentas e aplicações que serão mostradas neste capítulo, bem como as suas principais características utilizadas em cada etapa do processo.

5.2 Campanha de medições

A campanha de medições objetiva a obtenção de dados que descrevam como ocorre a transmissão de um vídeo em uma rede de computadores wireless, a fim de observar como se comporta o sinal irradiado e a degradação que sofrem os vídeos transmitidos no cenário específico. Os dados obtidos nas medições e utilizados para o desenvolvimento desta dissertação foram cedidos por (BATALHA, 2016).

5.2.1 Ferramentas Utilizadas nas Medições

Por meio do conjunto de ferramentas que serão descritas neste tópico, foi possível realizar a transmissão de um vídeo em uma rede de computadores. Estes instrumentos foram utilizados tanto para as transmissões de vídeo quanto para a obtenção da potência do sinal. A seguir, explicaremos a respeito de cada ferramenta e suas importâncias no desenvolvimento das medições.

5.2.1.1 Vídeo Utilizado

O vídeo escolhido foi o *Crowd Run*, obtido a partir do banco de dados (Xiph.org, 2017), com duração de 10 segundos e apresentando intensa

movimentação na imagem por quase toda a área do quadro (BATALHA, 2016). Amostras do vídeo estão presentes na Figura 17. Outras configurações são dadas abaixo:

- Codificação utilizada: x.264 - MPEG-4 AVC
- Resolução: 3840x2178
- Taxa de quadros: 25
- Formato decodificado: Planar 4:2:0 YUV
- Duração: 10s

Figura 17 - Frames do vídeo *Crowd Run* com diferentes valores de PSNR.



a) Frame 91 com PSNR 33,74 (dB)



b) Frame 91 com PSNR 15 (db)



c) Frame 91 com PSNR 11 (dB)

Fonte: (BATALHA, 2016).

5.2.1.2 EvalVid

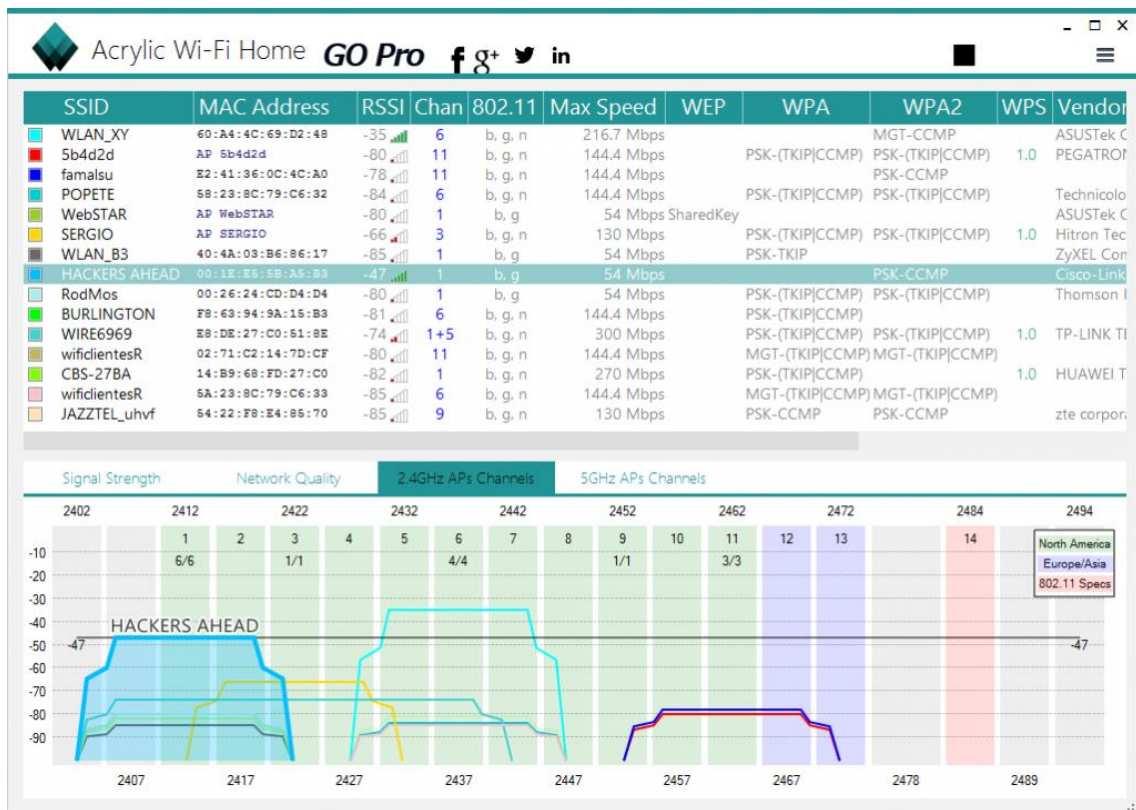
EvalVid é um *software* para avaliação de métricas de QoE e QoS, relacionado a vídeos e imagem digital e que possui um enorme conjunto de ferramentas utilizadas para avaliar a qualidade de vídeos transmitidos em uma

rede de comunicação simulada ou real. A utilização do EvalVid é útil para pesquisadores e projetistas de rede, pois permite a avaliação do comportamento da rede (EvalVid, 2017).

5.2.1.3 Acrylic

O *Acrylic* é um *software* de monitoramento do estado do adaptador de rede *wireless*, mostrado na Figura 18. Este programa é capaz de verificar as configurações da rede, testar o funcionamento do equipamento de rede sem fio, checar os níveis de intensidade do sinal, auxiliar na verificação de interferências, verificar as configurações de segurança, entre outras funções (Acrylic, 2017).

Figura 18 – Tela do programa *Acrylic*.



Fonte: (Acrylic, 2017).

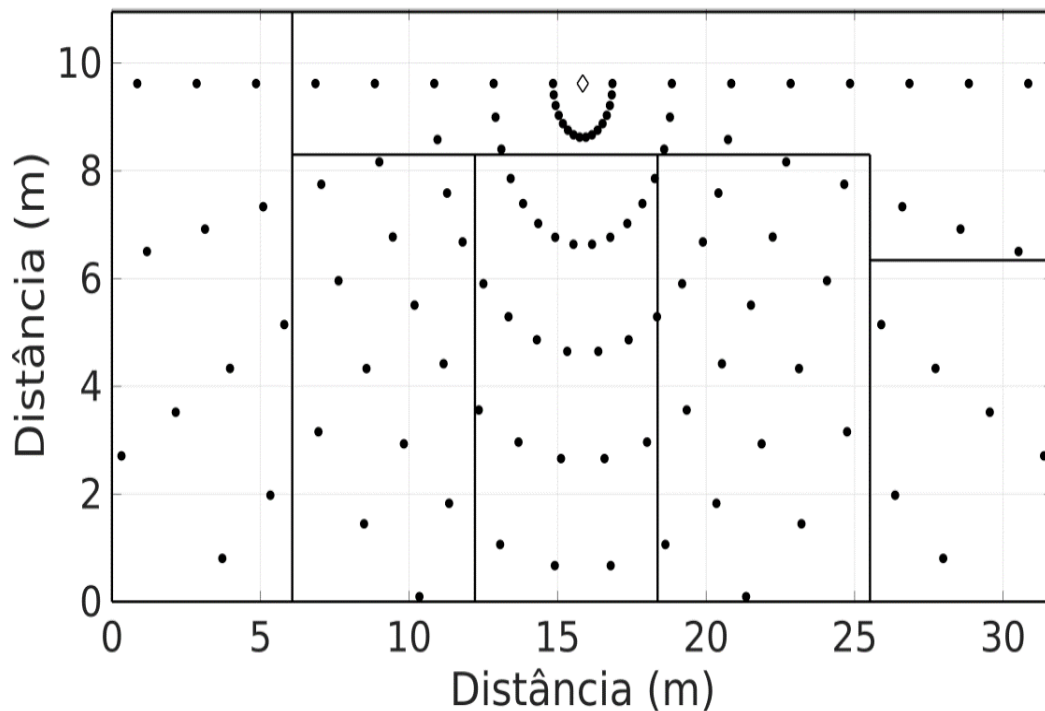
5.2.2 Cenário das Medições

As aferições foram realizadas nas dependências da UFPA (Universidade Federal do Pará), no Campus de Belém, no bloco de salas de aula do curso de engenharia de telecomunicações, que tem a dimensão de 30x11 metros, sendo constituído de cinco salas cada, contendo em seu interior mobílias (cadeiras e mesas) feitas de materiais plástico e metal.

O prédio de sala de aulas é construído por paredes de tijolos e concreto. Nesta etapa, foi feito o levantamento das informações sobre o ambiente a ser estudado, estabelecendo-se as localizações dos pontos a serem medidos e a localização do ponto de acesso.

A Figura 19 mostra um esquema do cenário onde foram realizadas as medições. Estão marcadas as localizações dos 110 pontos divididos em 16 radiais distribuídos de forma simétrica pelo cenário, assim como a localização do ponto de acesso.

Figura 19 - Esquema do cenário de medições.



5.2.3 Metodologia das Medições

O processo de medição é constituído da transmissão do vídeo descrito anteriormente em uma rede WLAN, sendo coletados dados a respeito de como ocorreu a transmissão. Em cada ponto medido, foram realizadas três transmissões a fim de obtermos uma maior precisão nos dados coletados. Foram utilizados os seguintes equipamentos: um ponto de acesso, um receptor USB, como pode ser visto na Figura 20, além de dois *notebooks*, abaixo serão descritas algumas especificações dos dispositivos utilizados (BATALHA, 2016):

1 - Roteador D-Link (DIR-803):

- Nome (SSID) "LCT_TESTE"
- Canal 1 (5.2 GHz)
- Modo 802.11ac
- Largura do canal 20 MHz
- Taxa de transmissão Máxima 433 Mbps
- Potência de transmissão de Máxima 15.5 dBm
- Ganho da Antena de 5 dBi

1 - Adaptador USB DWA-171

- Com suporte a padrão 802.11ac.

2 – *Notebooks*:

- Sistema Operacional *Windows 7*
- *Softwares EvalVid e a Acrylic* instalados em ambos.

Figura 20 – Equipamentos utilizados nas transmissões do vídeo.



a) Roteador D-Link DIR 803



b) Adaptador USB DWA-171

Fonte: (MATOS, 2017)

Desses dois *notebooks*, um foi utilizado para transmissão e outro para recepção do vídeo (Tx-vídeo e Rx-vídeo), por meio do uso da ferramenta EvalVid (EvalVid, 2017), para transmissões do vídeo através da rede WLAN. Nestas medições, foram coletados os seguintes parâmetros durante o processo: três arquivos referentes à transmissão, um no Rx-vídeo (rd.txt) e dois no Tx-vídeo e (st.txt e sd.txt), o nível de potência recebida (dBm), bem como o tipo de modulação e taxa de transmissão, todos coletados com o auxílio da ferramenta Acrylic (Acrylic, 2017) instalada em ambos os dispositivos Rx-vídeo e Tx-vídeo.

5.2.4 Tratamentos de dados

Após a obtenção dos dados, é necessário realizar o tratamento a fim de extrair conhecimento e transformá-los em informação. Para tanto, é necessário organizar e manipular esses dados de forma coerente, tendo em vista colocar em ordem ou simplesmente converter um arquivo para os diferentes tipos de formatos digitais, de forma que o conteúdo dos arquivos se mantenha consistente e fiel aos dados originais, podendo assim ser utilizados.

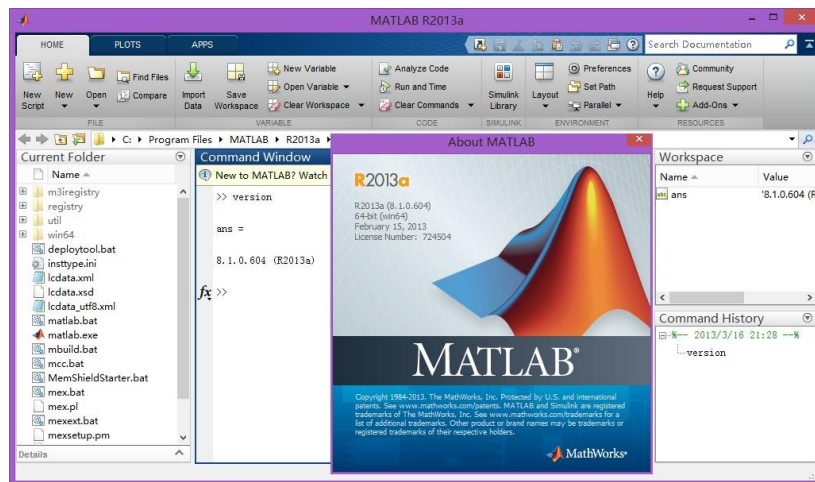
5.2.4.1 Ferramentas Utilizadas no Tratamento dos Dados

Através do conjunto de ferramentas que serão descritas neste tópico, foi possível a obtenção dos parâmetros de QoE das transmissões do vídeo na rede de computadores. Essas ferramentas foram utilizadas após as transmissões do vídeo, possibilitando a obtenção da métrica PSNR. A seguir, será explicada detalhadamente a contribuição de cada ferramenta em relação ao desenvolvimento do processo de tratamentos dos dados obtidos nas medições.

5.2.4.2 Matlab

MATLAB (MATrix LABoratory) é um *software* interativo de alta performance voltado para o cálculo numérico, mostrado na Figura 21. É capaz de realizar cálculo com matrizes, processar sinais e construir gráficos em um único ambiente (MATLAB, 2015).

Figura 21 - Software MATLAB

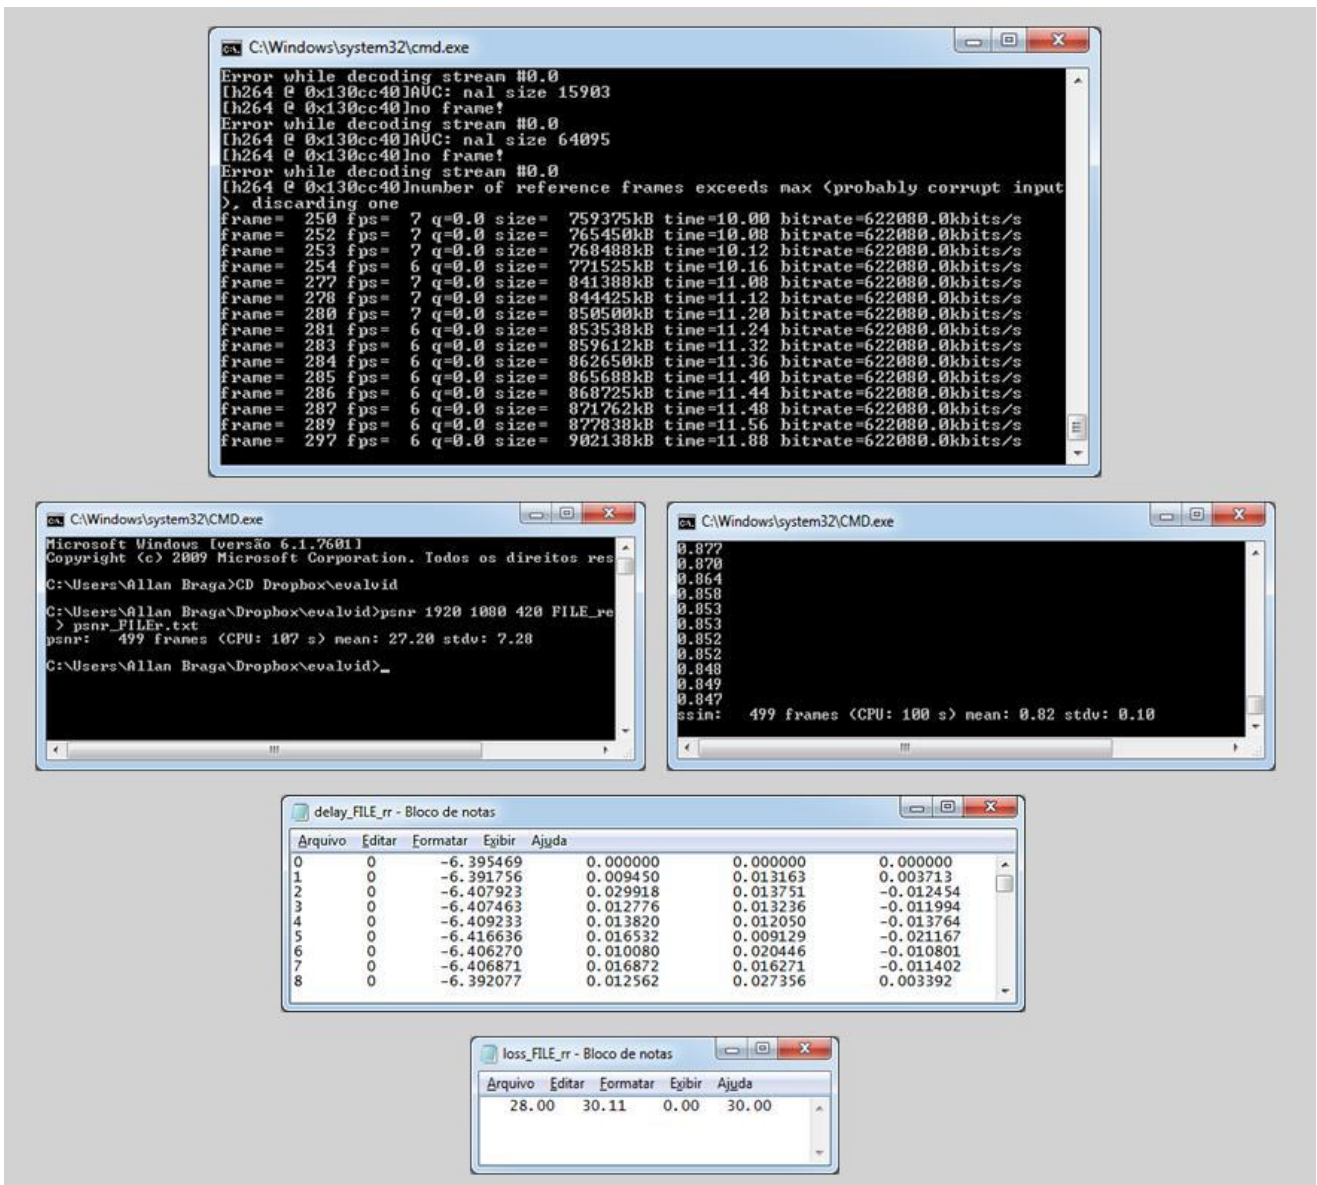


Fonte: (MATLAB, 2015)

5.2.4.3 Metodologia no Tratamento dos Dados

A partir da obtenção dos dados brutos das transmissões feitas pelo EvalVid, foi necessário tratar esses dados para extrair a métrica PSNR. Para isso, foi necessário reconstruir o vídeo transmitido utilizando o programa etmp4 (*Evaluate Traces of MP4-file Transmission*), que é um dos *softwares* do conjunto de ferramentas do EvalVid, e usado na reconstrução do vídeo recebido para o formato MPEG4 (.mp4), e depois, converter os arquivos reconstruídos do formato MP4 para o formato YUV através do aplicativo FFmpeg. Então, é possível comparar o arquivo original (sem degradação) e o arquivo reconstruído (com degradação), ambos no formato YUV, realizando os cálculos da PSNR utilizando o EvalVid (BRAGA, 2014), como mostrado na Figura 22.

Figura 22- Programa EvalVid em funcionamento e logs saída do mesmo.



Fonte: (BRAGA, 2014).

Após o tratamento destes dados citados anteriormente, foi possível obter informações suficientes para a aplicação na RNA, como será visto no tópico seguinte.

5.3 Métodos de Predição Indoor

Nesse trabalho, são apresentados dois métodos de predição por meio do uso de RNAs do tipo Perceptron de Múltiplas Camadas, um para predição de perda de PSNR e outro para predição de perda de propagação, ambos baseados em medições utilizando o padrão do IEEE 802.11ac, trabalhando na faixa de frequência de 5GHz em ambientes indoors caracterizados por sala de aulas.

Tendo os dados obtidos na campanha de medições e passados pela fase de tratamento dos dados, estes puderam ser aplicados no desenvolvimento das RNAs, como mostrado a Tabela 4.

Tabela 4 - Parâmetros aplicados no desenvolvimento das RNAs.

Parâmetros	Valores
Distância Tx e Rx (m)	2,4,6,8,10,12,14,16,18
Número de Paredes	0,1,2,3
Potência Recebida (dBm)	-45 até -73
Tipo de Modulação	BPSK, QPSK, QAM 16, 64 e 256
Taxa de transmissão (Mb/s)	97, 130, 155, 195, 260, 292, 325, 390, 433
Perda de PSNR (dB)	0 até 33,73

5.3.1 Métodos de predição para perda de PSNR (Descrição e Configuração das RNAs Utilizadas)


Há duas abordagens no desenvolvimento dos métodos de predição de perda de PSNR de redes sem fio indoor na faixa de 5GHz, utilizadas nesta pesquisa, sendo que em ambas é utilizado um método de regressão por meio de RNA. A 1ª abordagem utiliza 5 parâmetros de entrada em uma RNA (distância entre Tx e Rx, número de paredes, potência recebida, tipo de modulação e taxa de transmissão) para prever a perda de PSNR, e a 2ª abordagem, chamada de sistema de cascata, utiliza um conjunto de 4 RNAs em cascata, necessitando de apenas dois parâmetros como entrada (distância entre o transmissor e o receptor e número de paredes que obstruem o sinal).

A seguir, serão descritas de forma mais detalhada cada uma das abordagens citadas.

5.3.1.1 1ª Abordagem

A RNA foi implementada no software MATLAB© e consiste em uma Perceptron de Múltiplas Camadas (PMC), com 5 neurônio na camada de entrada, com função de ativação linear, 6 neurônios na camada escondida, com função de ativação sigmoide e na camada de saída temos 1 neurônio, com função de ativação linear, exibida na Figura 23. No treinamento supervisionado da RNA, foi o utilizado o algoritmo Levenberg-Marquardt.

Figura 23 - Rede PMC implementada.



Fonte: Próprio autor.

Para realização do treinamento da RNA, foram utilizadas 110 amostras distribuídas em três conjuntos de dados aleatoriamente, 78 pontos no conjunto de treinamento com 70% dos dados em relação ao total, os conjuntos de validação e teste continham 16 pontos cada, sendo 30% do total de amostras, como é exibido na Tabela 5.

Tabela 5 - Conjunto de treinamento.

Conj. de amostras	Número de amostras	% em relação ao total
Treinamento	78 pontos	70%
Validação	16 pontos	15%
Teste	16 pontos	15%


O treinamento baseia-se em apresentar um padrão às unidades da camada de entrada e, a partir desta camada, as unidades calculam sua resposta

que é produzida na camada de saída, o erro é calculado e, no segundo passo, este é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados.

Com isso, o erro vai sendo progressivamente diminuído, para identificar o ponto de parada de aprendizado, buscando obter a melhor taxa generalização da RNA. Uma alternativa é utilizar uma regra de parada, com base na técnica da validação cruzada, que consiste em validar os dados durante o treinamento da RNA, utilizando um conjunto de dados diferentes dos usados, para estimar os parâmetros durante o treinamento (HAYKIN, 2001).

O método consiste em acompanhar o progresso do aprendizado nas curvas correspondentes aos subconjuntos de dados de treinamento e de validação e teste, como é ilustrado na Figura 24. Deste modo, o treinamento é interrompido quando a curva de validação decresce a um erro mínimo, antes de começar a crescer, isto garante que não haja *overfitting* no treinamento.

Figura 24 - Progresso do erro de treinamento da RNA

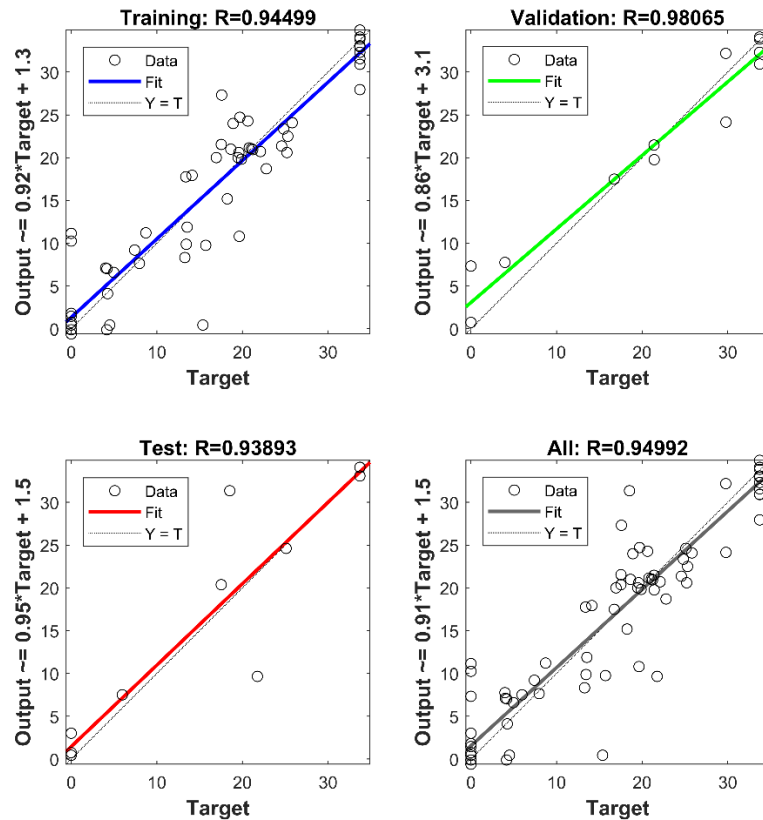


Fonte: Próprio autor.

A partir desse conjunto de dados, foram gerados os pesos que melhor representam o problema estudado. Logo, estando a RNA treinada e o erro em um nível satisfatório e com uma boa capacidade de generalização, é possível

observar a regressão linear realizada entre as saídas e os *targets*, na Figura 25, que poderá ser utilizada como uma ferramenta de predição.

Figura 25 – Regressão dos dados gerados pela RNA e seus respectivos *targets*.



Fonte: Próprio autor

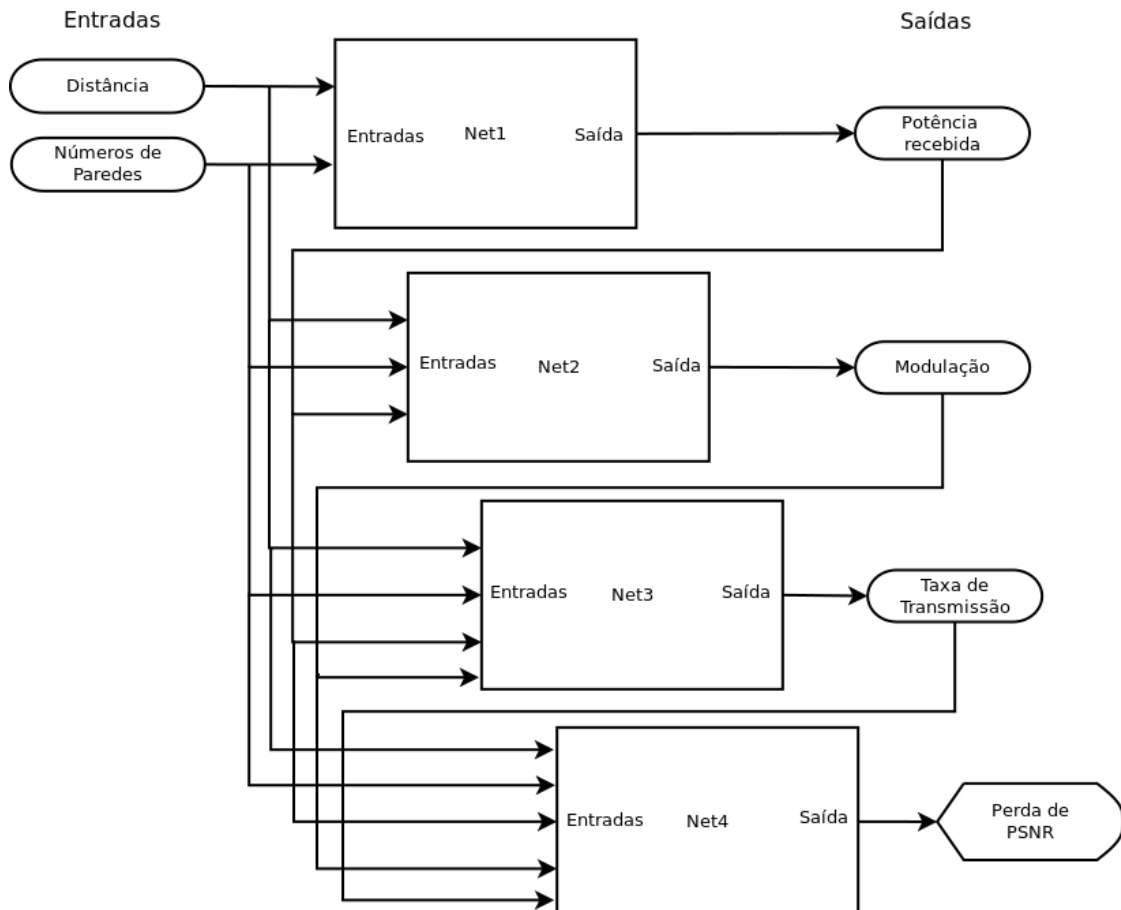
A linha preta significa o melhor coeficiente de correlação linear entre saídas e os *targets*. Os valores de R são uma indicação da relação entre as saídas e os *targets*. Se $R = 1$, isso indica que existe uma relação linear exata entre saídas e *targets*. Se R for próximo de zero, não existe uma relação linear entre saídas e alvos.

5.3.1.2 2ª Abordagem – Sistema em Cascata

A segunda abordagem trata-se de um arranjo de 4 RNAs na forma de cascata, onde a saída da primeira RNA é a entrada da segunda RNA e assim

sucessivamente, como mostra a Figura 26. A primeira RNA é responsável pela predição da potência recebida. Já a segunda, pela predição da modulação utilizada, enquanto a terceira, pela taxa de transmissão, e a quarta, por sua vez, é semelhante à da 1ª abordagem sendo responsável pela predição de perda de PSNR.

Figura 26 - Ilustração do Sistema de RNAs em cascata.



Fonte: Próprio autor.


As RNAs empregadas na segunda abordagem possuem a seguinte configuração: são Perceptron de Múltiplas Camadas (PMC), com a topologia de X neurônios na camada de entrada, com função de ativação linear. Na camada escondida, foi utilizada a função de ativação sigmóide, na camada de saída, temos 1 neurônio, com função de ativação linear. No treinamento das RNAs, foi utilizado o algoritmo Levenberg-Marquardt. Para garantir a capacidade de generalização das RNAs, foi utilizada a técnica de validação cruzada.

Para a realização do treinamento das RNAs, foram utilizadas as mesmas 110 amostras da 1ª abordagem, também distribuídas em três conjuntos de dados aleatoriamente, 78 pontos no conjunto de treinamento com 70% dos dados em relação ao total, os conjuntos de validação e teste continham 16 pontos cada, sendo 30% do total de amostras, como na Tabela 5. A seguir, serão descritas com mais detalhes cada uma das RNAs mencionadas, sendo designados a cada uma o nome de “NET”.

5.3.1.2.1 NET 1

Essa RNA é responsável por prever a potência do sinal recebido. Abrange 2 parâmetros de entrada: a distância e o número de paredes que o sinal atravessa no ambiente. Possui 16 neurônios na camada escondida, como mostra Figura 27.

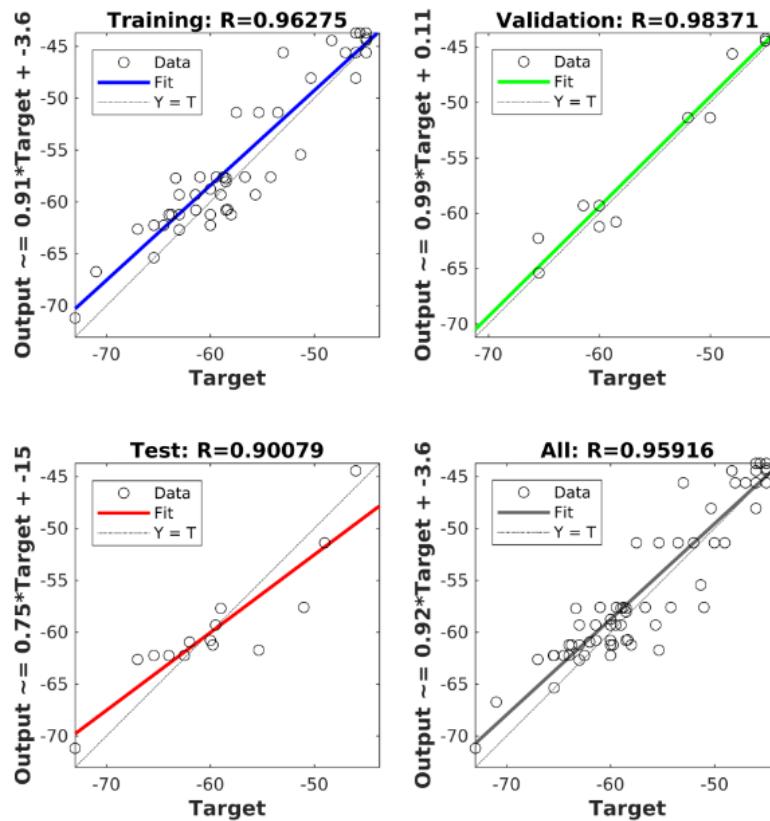
Figura 27 - Rede PMC, responsável por prever a potência do sinal recebido.



Fonte: Próprio Autor.

A partir do conjunto de dados, foram gerados os pesos que melhor representam o problema estudado, logo estando a RNA treinada e o erro em um nível satisfatório, é possível observar a regressão linear realizada entre as saídas e os *targets* na Figura 28, que demonstra uma boa capacidade de generalização.

Figura 28 – Regressão dos conjuntos de dados da NET1.




Fonte: Próprio autor.

5.3.1.2.2 NET 2

Essa RNA tem como objetivo prever o tipo de modulação utilizada nas transmissões do vídeo. É composta por 3 parâmetros de entrada: a distância, o número de paredes e a potência recebida, que, no sistema em cascata, será predita pela NET1. Possui uma topologia com 34 neurônios na camada escondida, como mostra a *Figura 29*.

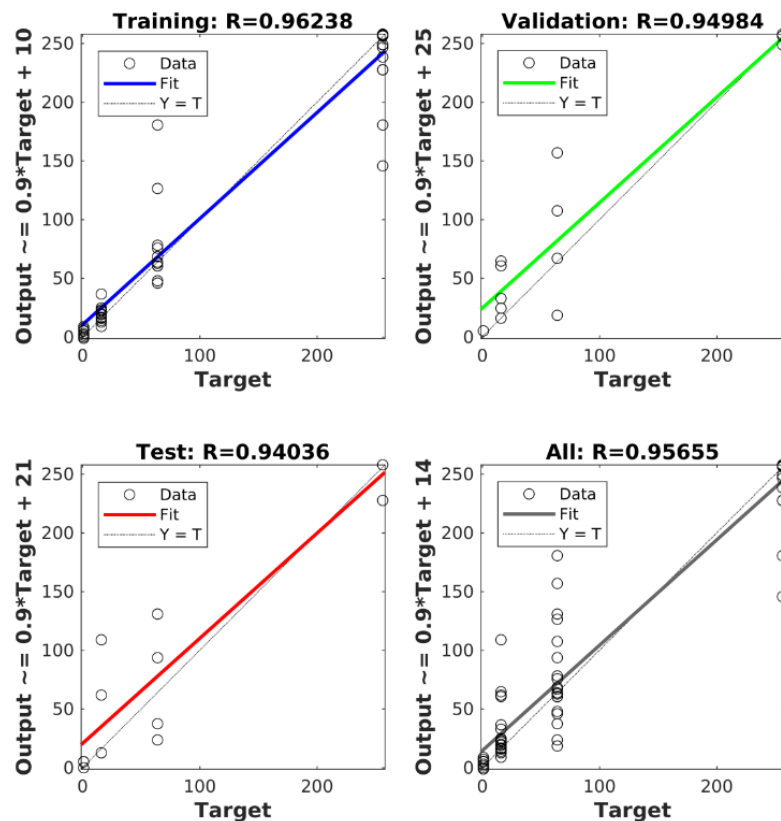
Figura 29 - Rede PMC, responsável por prever a modulação.



Fonte: Próprio autor.

A partir do conjunto de dados, foram gerados os pesos que melhor representam o problema estudado, logo estando a RNA treinada e o erro em um nível satisfatório, é possível observar a regressão linear realizada entre as saídas e os targets na Figura 30, que demonstra uma boa capacidade de generalização.

Figura 30 - Regressão dos conjuntos de dados da NET2.




Fonte: Próprio autor.

5.3.1.2.3 NET 3

Essa RNA tem como objetivo prever a taxa de transmissão do vídeo. É constituída por 4 parâmetros de entrada: a distância, o número de paredes, a potência recebida predita pela NET1 e o tipo de modulação predito pela NET2. Possui uma topologia com 10 neurônios na camada escondida, como mostra a Figura 31.

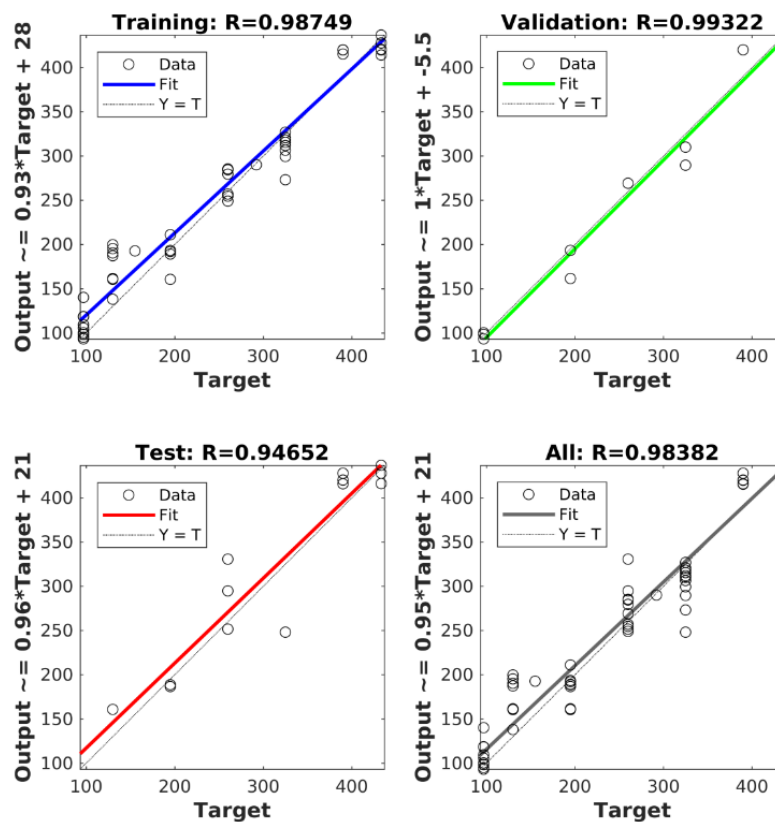
Figura 31 - Rede PMC, responsável por prever a taxa de transmissão.



Fonte: Próprio autor.

A partir do conjunto de dados, foram gerados os pesos que melhor representam o problema estudado, logo estando a RNA treinada e o erro em um nível satisfatório, é possível observar a regressão linear realizada entre as saídas e os targets na Figura 32, que demonstra uma boa capacidade de generalização.

Figura 32 - Regressão dos conjuntos de dados da NET3.




Fonte: Próprio Autor.

5.3.1.2.4 NET 4

Por último, temos a NET4. Essa RNA tem como objetivo prever a perda de PSNR. É formada por 5 parâmetros de entrada: a distância, o número de paredes, a potência recebida predita pela NET1, o tipo de modulação predito pela NET2 e a taxa de transmissão predita pela NET3. Possui uma topologia com 14 neurônios na camada escondida, como mostra a Figura 33.

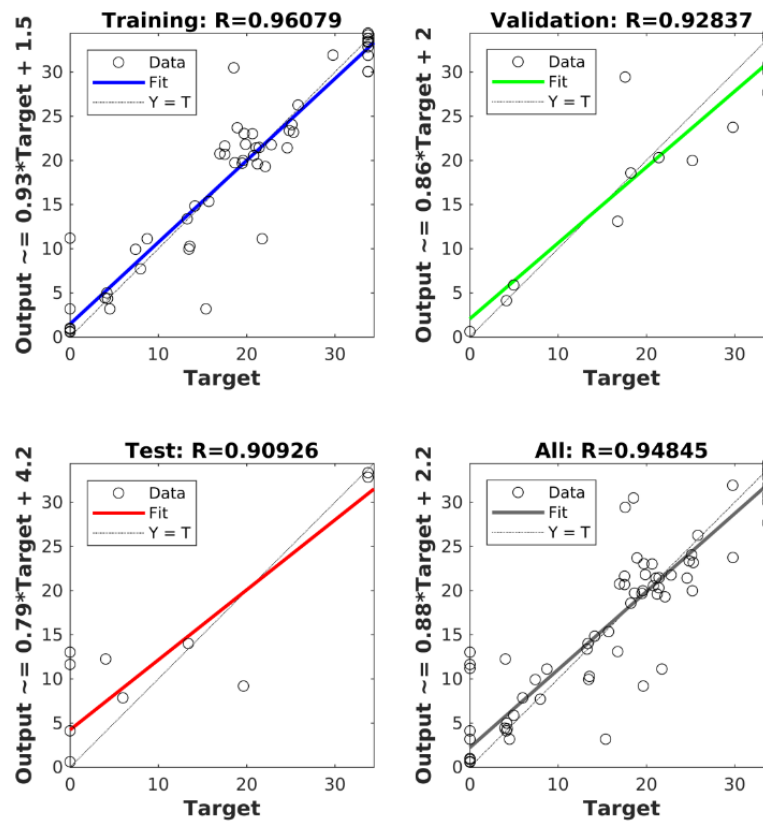
Figura 33 - Rede PMC, responsável por prever a perda de PSNR.



Fonte: Próprio autor.

A partir do conjunto de dados, foram gerados os pesos que melhor representam o problema estudado, logo estando a RNA treinada e o erro em um nível satisfatório, é possível observar a regressão linear realizada entre as saídas e os *targets* na Figura 34, que demonstra uma boa capacidade de generalização.

Figura 34 - Regressão dos conjuntos de dados da NET4.



Fonte: Próprio autor.

5.3.2 Modelo de Predição de Perda de Propagação

A partir dos dados obtidos na campanha de medições, foi possível implementar uma rede neural artificial (RNA) capaz de prever a potência recebida em determinado ponto levando em consideração fatores que caracterizam o ambiente como, por exemplo, a distância e o número de paredes que foram utilizadas como parâmetros de entrada da RNA. Conforme mostrado no item 5.2.1.21, NET1 da 2ª abordagem.

Desse modo, tendo os valores de potência recebida preditos pela RNA, foi utilizada a fórmula do balanceamento de Link da Equação 23 para se obter a perda de propagação. Esta fórmula leva em consideração todos os ganhos e perdas do transmissor e receptor em um sistema de telecomunicações.

$$L = P_{tx} - P_{rx} + G_{tx} + G_{rx} - L_{tx} - L_{rx} \quad (23)$$

Onde:

L: Perda de propagação (margem de desvanecimento, perda de corpo, perda de outros.) (dB);

P_{tx} : potência de saída do transmissor (dBm);

P_{rx} : potência recebida (dBm);

G_{tx} : ganho de antena transmissora (dBi);

G_{rx} : ganho de antena receptora (dBi);

L_{tx} : perdas do transmissor (cabo coaxial, conectores ...) (dB);

L_{rx} : perdas do receptor (coaxial, conectores ...) (dB).

Com isso, foi possível trabalhar com a predição de perda de propagação e comparar com o modelo empírico de perda de propagação da literatura, como veremos no capítulo de resultados.

5.4 Considerações finais

A metodologia empírica apresentada neste trabalho utiliza uma técnica de inteligência computacional, mostrando-se muito versátil, pois pode ser implementada com qualquer tecnologia existente, seja indoor ou outdoor, sendo necessárias apenas medições para a coleta de dados que descrevam o fenômeno a ser modelado. Dessa forma, basta tratar os dados coletados para a utilização em uma técnica de inteligência computacional para realizar uma regressão, a fim de inferir a relação de uma variável dependente com variáveis independentes específicas.

Neste capítulo, foi apresentado o desenvolvimento dos métodos propostos, capazes de prever a métrica de QoE, isto é, a perda de PSNR, além da qualidade do sinal através da perda de propagação, tendo como parâmetros métricas que relacionam as características do ambiente (distância entre Tx e Rx e número de paredes), bem como métricas da camada física de redes de computadores (nível do sinal recebido, o tipo de modulação e taxa de transmissão).

6 Análise e resultados

6.1 Considerações iniciais

Neste capítulo, serão apresentados os resultados obtidos a partir dos dados da saída das RNAs, sendo assim possível comparar com o conjunto de teste, o qual o sistema não teve acesso para o aprendizado, a fim de aferir a capacidade de predição deste.

Dessa maneira, foi possível comparar os valores dos dados referentes a QoE, através da métrica perda de PSNR, e também da qualidade do sinal, por meio da métrica perda de propagação, que foram obtidos através das medições e submetidos a fase de tratamentos de dados, com os valores de saída gerados pela RNA, utilizando como métrica de comparação a *root mean square deviation* (*erro RMS ou RMSE*) em português raiz do erro quadrático médio, sendo esta uma forma de avaliar a diferença entre um valor real e o estimado.

O erro RMS é a raiz quadrada da média do quadrado dos erros, com este cálculo resulta o montante pelo qual o valor real difere do valor estimado para avaliar a qualidade dos métodos de predição propostos. Pode ser calculada através da Equação 24, na qual n é o número de amostras, Vp é o valor fornecido pelo método (valor predito) para a i -ésima amostra e Vm é o valor medido em campo (valor real).

$$Erro\ RMS = \sqrt{\frac{\sum_{i=1}^n (Vp - Vm)^2}{n}} \quad (24)$$

Sendo:

- n = Número de amostra.
- Vp = Valor Predito.
- Vm = Valor Medido.

E ainda, com intuito de analisar os métodos de predição foram calculados os valores do desvio padrão do erro RMS entre os dados medidos e os preditos,

dados pela Equação 25. Quanto menor este valor mais preciso é o método, pois o desvio padrão representa o quanto os valores de uma variável se distanciam de sua média.

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (V - \mu)^2}{n}} \quad (25)$$

Sendo:

- V = uma variável aleatória de um conjunto de dados finito.
- μ = a média de V .
- n = Número de amostra.

Sendo ainda, os valores preditos comparados com o modelo empírico de perda de propagação e perda de PSNR de (BATALHA, 2016). Por último foram gerados mapas de cobertura da qualidade do vídeo e do sinal propagado no ambiente de estudo.

6.2 Métodos de predição de perda de PSNR

Este método de predição é baseado nos dados obtidos através de medições em um ambiente específico indoor (salas de aula), que se assemelha com ambientes de escritórios.


6.2.1 1ª Abordagem

Os dados obtidos na saída da Rede Neural Artificial, discutida no capítulo anterior, foram comparados com o conjunto de pontos de teste (o qual o sistema não teve acesso para o aprendizado), a fim de aferir a capacidade de predição desta metodologia.

Foram inseridos como parâmetros de entrada da ANN: distância entre Tx e Rx, número de paredes, potência recebida, modulação, taxa de transmissão de dados, de modo que gere um valor de perda de PSNR predito pelo RNA.

Assim, foi possível comparar os valores dos dados referentes a perda de PSNR, que foram obtidos através das medições, com os valores predito pela Rede Neural Artificial, exibidos na Figura 35. O erro RMS entre os dados medidos e os preditos é de 1,14 dB, com o desvio padrão de 1,02 dB.


Figura 35 – Comparação entre os valores de perda de PSNR medidos e preditos.



Fonte: Próprio autor

A Figura 36 proporciona uma análise mais completa do sinal propagado, pois considera o número de paredes atravessadas, a distância e a potência recebida em um determinado ponto. É possível ver a perda de PSNR aumentar conforme o número de paredes e distância aumenta, o que afeta a qualidade de experiência do usuário ao assistir um determinado vídeo.

Figura 36 – Relação entre a Perda de PSNR, distância, número de paredes e potência do sinal.



Fonte: Próprio autor.

A Tabela 6 mostra a perda média por parede, ou seja, o quanto o sinal é degradado ao atravessar uma parede, além de comparar os valores dessas perdas médias de PSNR entre os dados medidos e predito.

Tabela 6: Perda média por parede.

Número de Paredes	Potencia média Recebida (dBm)	Perda média PSNR Medida (dB)	Perda média PSNR Predita (dB)
0	-45,00	0,69	0,37
1	-58,08	8,19	9,63
2	-61,95	25,35	25,11
3	-68,33	33,74	35,70

Sendo assim, essa abordagem é capaz de prever a perda de PSNR de um vídeo sendo capaz de estimar a qualidade de experiência do usuário, por

outro lado, está se mostra um tanto trabalhosa, já que necessita de muitos dados de medições para prever a qualidade de vídeo. A sua vantagem é não necessitar reconstruir os vídeos transmitidos para se obter resultados relacionado a sua qualidade, algo que é bem demorado quando se trabalha com vídeo de ultra alta definição, além de obter valores muito precisos de perda de PSNR, valor esse que pode ser relacionado diretamente com a métrica de qualidade de vídeo subjetiva Mean Opinion Score (MOS), através da Tabela 7.

Tabela 7 - Relação entre PSNR e MOS.

PSNR	MOS
>37	5 (Excelente)
31-37	4 (Bom)
25-31	3 (Razoável)
20-25	2 (Pobre)
<20	1 (Ruim)


6.2.2 Sistema em cascata - 2ª abordagem

Os dados obtidos na saída das Redes Neurais Artificiais propostas no capítulo de metodologia foram comparados com o conjunto de pontos de teste (o qual o sistema não teve acesso para o aprendizado), a fim de aferir a capacidade de predição individual de cada rede (NETs) calculando-se o erro RMS bem como o erro RMS do sistema em cascata, formado pelo conjunto das quatro redes.

6.2.2.1 NET 1

Na NET1, foram inseridos dados provenientes das medições, referentes à distância do transmissor em relação ao receptor e ao número de paredes do ambiente estudado, como é visto na Figura 37.


Figura 37 – Estrutura da NET 1.



Fonte: Próprio autor.

Tendo está o intuito de prever a potência recebida no receptor. A Figura 38 mostra a saída da NET 1.

Figura 38 – Saída da NET 1.




Fonte: Próprio autor.

Dessa maneira, foi possível comparar os valores referentes a potência recebida, que foram obtidos através das medições, com os valores predito pela Rede Neural Artificial (NET1), obtendo um erro RMS 2,17 dB entre os dados medidos e os preditos, com um desvio padrão de 2,24 dB.

6.2.2.2 NET 2

Na NET2, exibida na Figura 39, foram inseridos dados provenientes das medições referentes à distância do transmissor em relação ao receptor, ao número de paredes e à potência recebida, com intuito de prever a modulação utilizada nas transmissões do vídeo que poderiam ser QPSK, 16QAM, 64QAM e 256QAM.

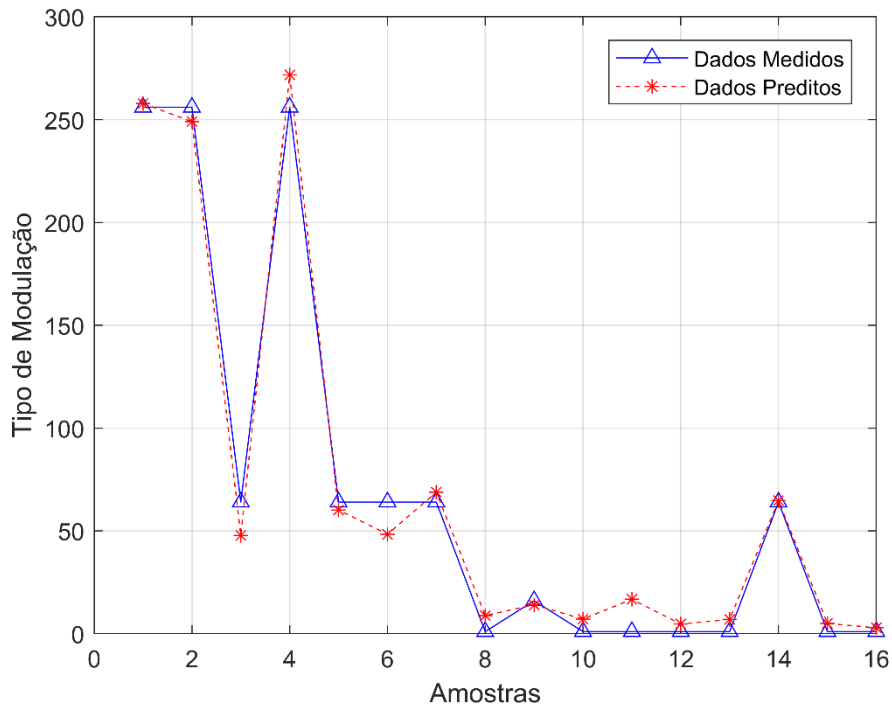
Figura 39 - Estrutura da NET 2.



Fonte: Próprio autor.

A Figura 40 mostra a saída da NET2.

Figura 40 - Saída da NET2



Fonte: Próprio autor.

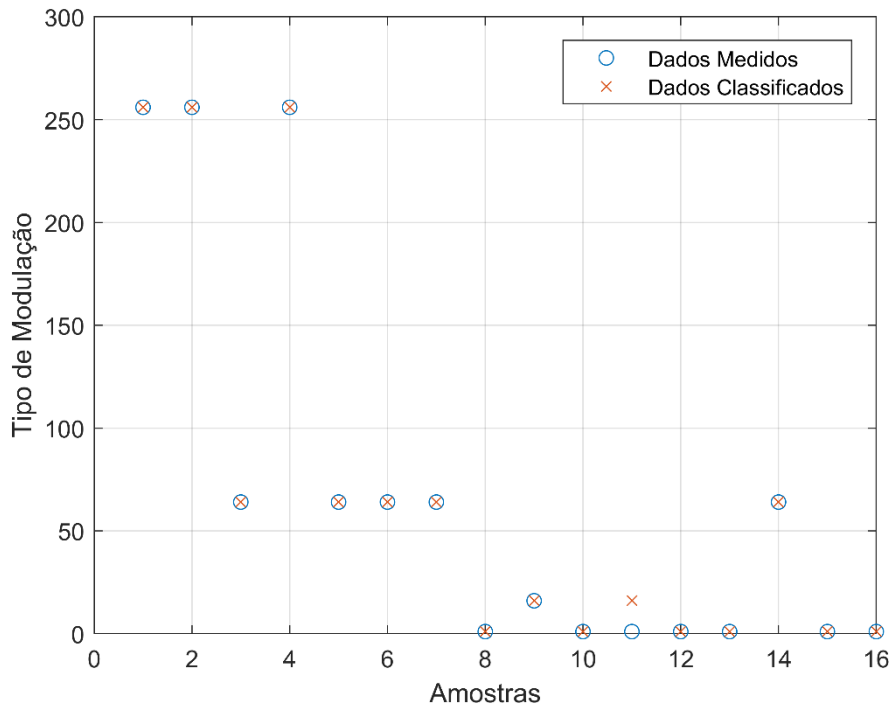
Para ajustar os valores da saída da NET2 em relação aos valores das modulações, foi feita uma simples classificação dos valores para o valor de modulação mais próximo como pode ser visto na Tabela 8.

Tabela 8 - Mapa de modulações utilizadas.

Valores de saída NET2	Tipo de Modulação
1 - 8	QPSK
9 - 32	16QAM
33 - 64	64QAM
65 - 256	256QAM

Com isso, foi possível se obter uma taxa de classificação de 93,75 %. Como é mostrado na Figura 41, foram classificados corretamente 15 amostras de 16.

Figura 41 – Classificação da modulação utilizada na transmissão.

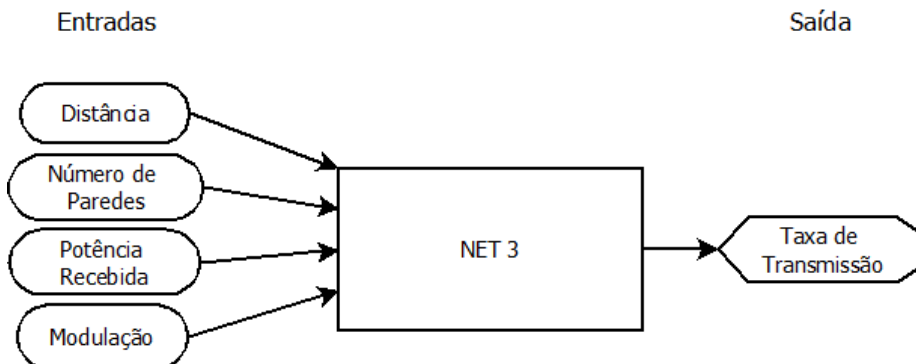


Fonte: Próprio autor.

6.2.2.3 NET 3

Na NET3, exibida na Figura 42, foram inseridos dados provenientes das medições referentes à distância do transmissor em relação ao receptor, ao número de paredes, à potência recebida e ao tipo de modulação, com intuito de prever a taxa de transmissão de dados, utilizada nas transmissões do vídeo que poderiam ser 97, 130, 155, 195, 260 ,292 ,325, 390, 433 Mb/s.


Figura 42 - Estrutura da NET 3.



Fonte: Próprio autor.

A Figura 43 mostra a saída da NET3.

Figura 43 - Saída da NET3.



Fonte: Próprio autor.


Para ajustar os valores da saída da NET3 aos valores de taxas de transmissões, foi feita uma simples classificação dos valores para o valor de taxa de transmissões mais próximo, como pode ser visto na Tabela 9.

Tabela 9 - Mapa de taxas de transmissão utilizadas.

Valores de saída NET3	Taxa de Transmissões
1 – 113,5	97 Mb/s
113,6 – 162,5	130 Mb/s
162,6 – 227,5	195 Mb/s
227,6 – 276,5	260 Mb/s
276,6 – 308,5	292 Mb/s
308,6 – 357,5	325 Mb/s
357,6 – 411,5	390 Mb/s
411,6 - 500	433 Mb/s

Com isso, foi possível se obter uma taxa de classificação de 93,75 %. Como é mostrado na Figura 44, foram classificados corretamente 15 amostras de 16.

Figura 44 – Classificação da taxa de transmissão do vídeo.




Fonte: Próprio autor.

6.2.2.4 NET4

A NET4, exibida na Figura 45 é similar a rede desenvolvida na 1ª abordagem, na qual são inseridos como parâmetros de entrada da RNA a distância entre Tx e Rx, o número de paredes, a potência recebida, o tipo de modulação e a taxa de transmissão de dados, de modo que gere um valor de perda de PSNR predito pelo RNA.

Figura 45 - Estrutura da NET 4.




Fonte: Próprio autor.

Desse modo, foi possível comparar os valores dos dados referentes à perda de PSNR, que foram obtidos através das medições, com os valores predito pela Rede Neural Artificial, exibido na


Figura 46 a). O erro RMS entre os dados medidos e os preditos é de 1,48 dB e o desvio padrão de 1,15 dB. A

Figura 46 b) e c) são os respectivos valores de distância entre Tx e Rx e número de paredes, utilizados na confecção das NETs.


Figura 46 – Saída da NET4.



a)



b)




c)

Fonte: Próprio autor.

6.2.2.5 Saída do sistema em cascata

Após ter criado cada uma das redes neurais artificiais (NETs) que compõem o sistema em cascata, tornou-se possível sua implementação a partir da inserção dos valores de distância entre transmissor e receptor e número de paredes do ambiente como entrada do sistema em cascata. É possível prever a potência recebida com a utilização da NET1, que servirá como entrada da NET2 para predição da modulação, que servirá como entrada da NET3 para predição da taxa de transmissão, que servirá como entrada da NET4 para predição de perda de PSNR. A Figura 47 mostra a saída do sistema em cascata.

Figura 47 – Saída do sistema em cascata.




Fonte: Próprio autor.

O sistema em cascata obteve um erro RMS 2,81 dB em relação aos dados medidos, com um desvio padrão de 2,89 dB. A grande vantagem do sistema em cascata é que, para sua utilização, são necessárias apenas duas informações sobre o ambiente: distância entre o transmissor e o receptor e número de paredes. Apesar de ter demonstrado um valor de erro RMS maior que a 1ª abordagem, ainda assim é bem mais prático.

Na Figura 48, são exibidos os valores preditos pelo sistema em cascata, para distância de 1 até 16 metros com visada direta, com obstrução por 1, 2 e 3 paredes.

Figura 48 – Comportamento do método de previsão de perda de PSNR proposto.




Fonte: Próprio autor.

Na Figura 47, há uma sobreposição das curvas, o que demonstra uma certa imprecisão do método de previsão, que são explicáveis pelo fato de que a regressão é feita de forma empírica, em cima dos dados medidos, os quais não possuíam dados, por exemplo, da obstrução do sinal para três paredes para distância de 1 metro, pelo fato de ser algo bem incomum para o ambiente estudado. Isso demonstra que este método de previsão tem que ser utilizado em ambientes semelhantes aos quais foram feitas as medições que o originaram.

Apesar do que foi mencionado, os resultados obtidos pelo sistema em cascata se mostram satisfatórios, tendo seus valores de perda inicial e final coerentes. A partir disto, foram gerados mapas de calor do ambiente estudado, com valores de perda de PSNR gerados pelo método de previsão desenvolvido nesta dissertação, exibido na Figura 49, o que prova que este pode ser utilizado para planejamentos de redes sem fio indoor, na faixa de 5GHz, visando à qualidade experiência do usuário ao assistir um vídeo.


Figura 49 – Mapa de cobertura, baseado no método de predição de perda de PSNR.



Fonte: Próprio autor.

A Figura 50 demonstra a área coberta capaz de suportar a transmissão de um vídeo 4k com boa qualidade, baseada na Tabela 7 mencionada anteriormente.

Figura 50 - Mapa da área de cobertura, com boa qualidade de vídeo.



Fonte: Próprio autor.

6.2.3 Comparação com modelo de qualidade de vídeo

Esta seção é dedicada a comparação do método de predição de perda de PSNR, por meio do sistema em cascata proposto neste trabalho, com o modelo de predição de perda de PSNR Batalha, proposto em (BATALHA, 2016), sendo este descrito pela Equação 26.

Ambos utilizaram os mesmos dados de medições para realizar regressão, utilizando técnicas diferentes. O método proposto utiliza RNA, com dois parâmetros de entrada distância entre Tx e Rx e número de paredes obstruindo o sinal, já o modelo Batalha emprega mínimos quadrados lineares, sendo que este utiliza apenas a potência recebida como parâmetro de entrada.

$$L_{PSNR} = 44,9212 - 43,2770e^{\left(\frac{pr - (-45)}{17}\right)} \quad (26)$$


Onde:

L_{PSNR} = perda de PSNR;

pr = potência recebida em dB.

Na Figura 51 é exibida a comparação, o valor do erro RMS entre os dados medidos e os dados preditos pelo o modelo Batalha foram de 6,62 dB e desvio padrão de 6,00 dB, enquanto para o método em cascata que utilizou o conjunto de quatro RNAs foi de 2,81 dB com desvio padrão de 2,89 dB.

Figura 51 – Comparação entre o método em cascata e o modelo Batalha para predição de perda de PSNR.



Fonte: Próprio autor.


6.3 Método de Predição de Perda de Propagação indoor

Os dados obtidos na saída da Rede Neural Artificial proposta foram comparados com o conjunto de pontos de teste (o qual o sistema não teve acesso para o aprendizado) a fim de aferir a capacidade de predição deste método.


Foram inseridos como parâmetros de entrada na RNA os valores de distância entre Tx e Rx e número de paredes obstruindo o sinal, de modo que gere um valor de perda de propagação predito pelo RNA.

Assim, foi possível comparar os valores dos dados referentes à perda de propagação, que foram obtidos através das medições, com os valores predito pela Rede Neural Artificial, exibido na Figura 52. O erro RMS entre os dados medidos e os preditos é de 2,17 dB e desvio padrão de 2,24 dB.


Figura 52 – Saída da RNA, responsável pela previsão de perda de propagação.



a)



b)




c)

Fonte: Próprio autor.

Com a RNA treinada e testada, foi possível traçar a perda de propagação para cada número de parede e distância com até 16 metros para demonstrar o comportamento do método proposto de predição baseado em RNA, como é exibido na Figura 53.

Figura 53 - Comportamento do método de predição de perda de propagação proposto.




Fonte: Próprio autor.

Tanto a perda inicial quanto a perda final do método proposto se mostram condizentes, mas, em alguns momentos na Figura 53, pode se observar uma sobreposição das curvas, a qual mostra a curva de perda de propagação para 3 paredes, menor que para de uma parede, isso se deve ao fato, de não haver medições para 3 paredes em distâncias menores que 12 metros nos dados coletados.

A Figura 54 exibe o mapa de cobertura do ambiente estudado, gerado a partir do método de predição de perda de propagação apresentado neste trabalho. O ponto de acesso é representado pelo asterisco, as cores mais frias representam valores com menores perdas de propagação, enquanto as cores mais quentes indicam valores com maiores perdas de propagação.


Figura 54 - Mapa de cobertura, baseado no método de previsão de perda de propagação.



Fonte: Próprio autor.

A Figura 55 mostra a área de cobertura do sinal, onde é possível se obter um valor de perda de propagação aceitável para que o vídeo apresente uma qualidade boa de visualização.

Figura 55 - Mapa da área de cobertura, com boa qualidade de sinal.



Fonte: Próprio autor.

6.3.1 Comparação com modelo de perda de propagação

A fim de demonstrar a acurácia do método proposto, foi realizada uma comparação com o modelo matemático empírico de perda de propagação indoor (Batalha, 2016), o qual leva em consideração também a distância e o número de paredes do ambiente demonstrado na Equação 24. Ambos os trabalhos utilizaram os mesmos dados para o desenvolvimento da modelagem, só que com técnicas diferentes. O modelo Batalha utilizou mínimos quadrados e o método proposto utiliza RNA para realizar uma regressão nos dados medidos, dados estes obtidos através de medições por (Batalha, 2016).

$$L = -25,7363 + 10n\log_{10}(d) + 20\log_{10}(f) + lm(np) \quad (27)$$

Onde:

L : perda em dB;

n : coeficiente de atenuação com a distância;


d : distância em metros;

lm : coeficiente de atenuação por paredes;

np : número de paredes atravessadas.

A Figura 56 mostra essa comparação, sendo que o valor do erro RMS entre os dados medidos e os dados preditos pelo o modelo Batalha foram de 5,41 dB e desvio padrão de 4,76 dB enquanto para o método que utilizou RNA foi de 2,17 dB com desvio padrão de 2,24 dB.

Figura 56 - Comparação entre o método RNA e o modelo Batalha para predição de perda de propagação.



Fonte: Próprio autor.

A Tabela 10 mostra a perda de propagação média por parede atravessada, ou seja, o quanto o sinal é degradado ao atravessar uma ou mais paredes, além de comparar os valores médios das perdas de propagação entre os dados medidos e dos modelos.

Tabela 10: Perda média por parede.

Número de Paredes	Perda de Propagação Medida (dB)	Método RNA (dB)	Modelo Batalha (dB)
0	66.52	65.96	56.50
1	74.92	74.61	73.12
2	81.58	81.40	78.95
3	87.02	84.26	87.61

7 Conclusões e trabalhos futuros

7.1 Conclusões

Esta dissertação apresentou uma abordagem *cross-layer*, que estuda a relação entre camada física e a camada de aplicação, além de levar em consideração as características do ambiente, que evidenciam a influencia na qualidade de um vídeo transmitido em uma rede 802.11ac, em um ambiente *indoor*, é afetada conforme varia a qualidade do canal de transmissão.

Utilizando uma metodologia empírica baseada em campanhas de medições, a fim de se obter dados referentes à qualidade de vídeo, em um ambiente específico, considerando os fatores que podem afetar a propagação de uma onda eletromagnética, tais como paredes (de tijolo e madeira), portas e janelas, além de objetos que compunham o cenário em questão, como cadeiras e mesas.

Tendo a intenção de prever a perda de PSNR de um vídeo e a perda de propagação do sinal, aplicando uma técnica de inteligência computacional, chamada de Redes Neurais Artificiais, que é capaz de relacionar um conjunto de dados de treinamento, para inferir resultados pertinentes, baseados no conhecimento adquirido pelo conjunto de dados repassado a RNA.

Para aferir os resultados da metodologia, foram comparados os dados de saída desse sistema (dados preditos) com os dados obtidos nas campanhas de medições (dados reais). Para avaliar o desempenho dos métodos propostos, foram escolhidos como parâmetros a raiz do erro médio quadrático (erro RMS), e o desvio padrão do erro RMS entre os dados preditos e os medidos.

Os resultados obtidos com os métodos de predição de perda de PSNR se mostraram satisfatórios, na 1ª abordagem na qual utiliza cinco parâmetros de entrada, a RNA se mostrou muito precisa, na comparação entre a saída da RNA da 1ª abordagem (dados preditos) e os dados medidos, obteve-se uma taxa de erro RMS de 1,14 dB, com o desvio padrão de 1,02 dB.

Já na 2ª abordagem, o sistema em cascata obteve um erro RMS 2,81 dB em relação aos dados medidos, com um desvio padrão de 2,89 dB. A grande

vantagem do sistema em cascata é que, para sua utilização, são necessárias apenas duas informações sobre o ambiente: distância entre o transmissor e o receptor e número de paredes. Apesar de ter demonstrado um valor de erro RMS maior que a 1ª abordagem, ainda assim é bem mais prático.

O método de predição de perda de propagação obteve um erro RMS entre os dados medidos e os preditos pela RNA de 2,17 dB e desvio padrão de 2,24 dB.

Desse modo, a partir dos resultados fornecidos pelos métodos propostos, é possível auxiliar nos futuros planejamentos de redes de computadores sem fio homologadas no padrão 802.11ac em ambientes indoor, levando em consideração não somente a qualidade do sinal fornecida ao usuário, mas também a QoE, tendo como parâmetro a qualidade de vídeo prestada ao usuário na rede.

7.2 Trabalhos Futuros

Para trabalhos futuros, pretende-se aperfeiçoar a capacidade de predição das redes neurais artificiais (sistema em cascata) propostas, com o objetivo de sejam capazes de prever, outras métricas de QoE (SSIM e VQM), além da perda de PSNR e de propagação, em diferentes cenários *indoor* e *outdoors*. Para isso, é necessário realizar medições em diferentes cenários visando um treinamento com dados mais heterogêneos.

Nessa perspectiva, também seria interessante expandir as medições para outras faixas de frequência e padrões de redes sem fio (Wi-Fi), tais como o 802.11ad e o 802.11ax, além de utilizar vídeos com resoluções maiores como: 2K, 4k e 8k. Esta metodologia utilizada no trabalho também poderia ser utilizada em ambientes *outdoors*, com outras tecnologias, como, por exemplo, o WIMAX, 4G e 4,5G.

Referências

Acrylic. (2017). Acesso em 05 de maio de 2017, disponível em <https://www.acrylicwifi.com/en/wlan-software/wlan-scanner-acrylic-wifi-free/>

ARAÚJO, J. P. (2011). *Estratégia de planejamento e otimização de sistemas sem fio, considerando redes interferentes: abordagem baseada em crosslayer*. Tese (Doutorado), UFPA, Programa De Pós-graduação Em Engenharia Elétrica.

Bashorun, O., & et al., S. O. (2017). Analysis and Prediction of Indoor wireless Propagation Using adaptive Neuro-Fuzzy Inference System. *Pacific Journal of Science and Technology*. 18(2):155-162.

BATALHA, I. d. (2016). *Estudo da tecnologia IEEE 802.11ac para o desenvolvimento de modelos empíricos e cross-layer*. UFPA, Programa De Pós-graduação Em Engenharia Elétrica. Dissertação (Mestrado).

BRAGA, A. S. (2014). *Planejamento De Redes De Comunicação Sem Fio Para Ambientes Indoor Considerando Aplicações Multimídia: Abordagem Híbrida - Simulação E Medição*. Dissertação de Mestrado em Engenharia Elétrica, UFPA, Programa De Pós-graduação Em Engenharia Elétrica, Belém.

DANISH, E., & et al., A. M. (2016). Cross-layer QoE prediction for mobile video based on random neural networks. *IEEE International Conference on Consumer Electronics (ICCE)*, (pp. pp. 227-228). Las Vegas, NV. doi:10.1109/ICCE.2016.7430591

EvalVid. (05 de maio de 2017). Fonte: <http://www2.tkn.tu-berlin.de/research/EvalVid/EvalVid/docEvalVid.html>

Filho, O., & Neto, H. (1999). Em *Processamento Digital de Imagens*. Editora: Brasport Livros e Multimídia Ltda.

HAYKIN, S. (2001). *Redes Neurais: Princípios e prática* (2ª ed.). Ed. Bookman.

M. Alreshoodi, A. O.-E. (2015). Fuzzy logic inference system-based hybrid quality prediction model for wireless 4kUHD H.265-coded video streaming. *IET Networks*, vol. 4, no. 6, pp. pp. 296-303. doi:10.1049/iet-net.2015.0018

MATLAB. (2015). Fonte: The MathWorks Inc: <http://www.mathworks.com>

MATOS, E. M. (2017). *Qualidade De Vídeo Baseada Em Perda de pacotes utilizando o padrão IEEE 802.11ac*. Dissertação (Mestrado), UFPA, Programa de Pós-Graduação em Engenharia Elétrica.

MENDES, D. R. (2007). *Redes de Computadores Teoria e Prática*. São Paulo: Novatec.

Network Types. (2017). Acesso em 03 de 12 de 2017, disponível em STATISTICA:
<http://documentation.statsoft.com/STATISTICAHelp.aspx?path=SANN/Overview/SANNOverviewsNetworkTypes>

Redes WLAN. Acesso em 05 de maio de 2017 . Fonte: <http://www.ti-redes.com/wireless/wlan-intro/>

Shen, Y. e. (2012). QoE-based Evaluation Model on Video Streaming Service Quality. *IEEE Globecom Workshops (GC Wkshps)*. doi:10.1109/GLOCOMW.2012.6477772

Silva, I. N., Spatti, D. H., & Flauzino, R. A. (2010). *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático*. São Paulo, SP, Brasil: Artliber Editora Ltda.

Site Transcortec. (12 de maio de 2017). Fonte: <http://www.transcortec.com.br/interface-hdmi.php>

TANENBAUM, A. S. (2003). *Redes de Computadores* (4ª edição ed.). Campus (Elsevier).

Tian, Y., & Zhu, M. (2009). Analysis and Modelling of No-Reference Video Quality Assessment. *IEEE Conference on Computer and Automation Engineering*, (pp. pp. 108-112).

Wiegand, T., Sullivan, G. J., Bjontegaard, G., & Luthra, A. (2003). Overview of the H.264/AVC video coding standard. *IEEE Circuits and Systems Society*, 13(7), 560 - 576. doi:10.1109/TCSVT.2003.815165

Wikipedia. (2017). Acesso em 12 de maio de 2017, disponível em <http://es.wikipedia.org/wiki/YUV>

Wikispaces. (2017). Acesso em 22 de fevereiro de 2017, disponível em <https://wirtschaftsinformatikbkal.wikispaces.com/LAN%2C+WLAN%2C+WAN>

Xiph.org. (2017). Acesso em 21 de Fevereiro de 2017, disponível em Xiph.org - Self-produced videos to spread techie-level knowledge: www.xiph.org/video/

Z. Wang et al., H. R. (2003). *Objective Video Quality Assessment, The Handbook of Video Databases: Design and Applications*. CRC Press.

Zambiasi, P. D. (2013). *Redes Neurais Artificiais*. Notas de Aula.