



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDREIA COELHO DOMINGOS

**COMPARAÇÃO ENTRE AS REDES LVQ E MLP NA PREVISÃO DA ATENUAÇÃO
PROVOCADA PELA CHUVA**

UBERLÂNDIA

2022

ANDREIA COELHO DOMINGOS

**COMPARAÇÃO ENTRE AS REDES LVQ E MLP NA PREVISÃO DA ATENUAÇÃO
PROVOCADA PELA CHUVA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como exigência parcial para obtenção do título de mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Gilberto Arantes Carrijo

UBERLÂNDIA

2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

D671 2022	<p>Domingos, Andreia Coelho, 1995- Comparação entre as Redes LVQ e MLP na previsão da atenuação provocada pela chuvas [recurso eletrônico] / Andreia Coelho Domingos. - 2022.</p> <p>Orientador: Gilberto Arantes Carrijo. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Elétrica. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2022.205 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Engenharia elétrica. I. Carrijo, Gilberto Arantes , 1948-, (Orient.). II. Universidade Federal de Uberlândia. Pós-graduação em Engenharia Elétrica. III. Título.</p> <p style="text-align: right;">CDU: 621.3</p>
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

ANDREIA COELHO DOMINGOS

**COMPARAÇÃO ENTRE AS REDES LVQ E MLP NA PREVISÃO DA ATENUAÇÃO
PROVOCADA PELA CHUVA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como exigência parcial para obtenção do título de mestre em Engenharia Elétrica.

Área de concentração: Processamento digitais de sinais.

Uberlândia, 09 de maio de 2022.

Banca Examinadora:

Prof. Dr. Giberto Arantes Carrijo

(Orientador – UFU)

Prof. Dr. Alexandre Coutinho Mateus

(Examinador – UFU)

Prof. Dr. Benedito Alencar Arruda

(Examinador – UFMT)



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Dissertação de Mestrado Acadêmico, 773, PPGEELT				
Data:	Nove de maio de dois mil e vinte e dois	Hora de início:	08:30	Hora de encerramento:	11:30
Matrícula do Discente:	12012EEL001				
Nome do Discente:	Andreia Coelho Domingos				
Título do Trabalho:	Comparação entre as redes LVQ e MLP na previsão da atenuação provocada pela chuva				
Área de concentração:	Processamento da informação				
Linha de pesquisa:	Processamento digital de sinais				
Projeto de Pesquisa de vinculação:	Coordenador do projeto: Gilberto Arantes Carrijo e Edgar Silva Júnior. Título do projeto: MODELOS DE PROPAGAÇÃO MICROCELULARES EM ÁREAS URBANAS E MÓVEIS PARA FREQUÊNCIAS DE UHF E MICROONDAS. Agência financiadora: Fundação de Pesquisa do Estado da Bahia. Número do processo na agência financiadora: ___ Vigência do projeto: 2016- até a atual data.				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Alexandre Coutinho Mateus - FEELT/UFU; Benedito Alencar de Arruda - UFMT; Gilberto Arantes Carrijo - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Gilberto Arantes Carrijo, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Alexandre Coutinho Mateus, Professor(a) do Magistério Superior**, em 09/05/2022, às 10:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Gilberto Arantes Carrijo, Professor(a) do Magistério Superior**, em 09/05/2022, às 10:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Benedito Alencar de Arruda, Usuário Externo**, em 09/05/2022, às 10:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site

[https://www.sei.ufu.br/sei/controlador_externo.php?](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento_conferir&id_orgao_acesso_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3558301** e o código CRC **ECFD7D4A**.

Dedico este trabalho a Deus, o maior orientador da minha vida. Ele nunca me abandonou nos momentos de necessidades. E aos meus pais. Esta dissertação é a prova de que todo investimento e dedicação valeram a pena.

AGRADECIMENTOS

Nesses anos de mestrado, que foram repletos de muitos estudos, esforços e dedicações, gostaria de agradecer a algumas pessoas que me apoiaram e me ajudaram a realizar mais um dos meus sonhos. Como resultado, gostaria de compartilhar um pouco do significado que elas tiveram, e continuam tendo, minhas sincera gratidão a todas elas. Primeiramente queria agradecer a Deus, pela minha vida, por me ajudar a ultrapassar todos os obstáculos encontrados ao longo do mestrado. Obrigada por ser a minha força e o meu guia em todos os momentos. A ti, Senhor, toda honra e toda a glória.

Aos meus pais, Antônio e Mariângela, que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu dedicava à realização deste projeto. Suas orações me deram forças para continuar e finalizar esta pesquisa.

Aos meus irmãos, Daniela e Gustavo, pela amizade, atenção dedicadas quando sempre precisei, pela cumplicidade e pelo apoio em momentos delicados em minha vida. Obrigada por estar ao meu lado e por me fazer ter confiança nas minhas decisões.

Ao Pastor Ronan, agradeço pela dedicação, empenho e conhecimento no trabalho e pregação da Palavra de Deus para nós! Obrigada pelas suas palavras, empatia e amizade, o senhor fez diferença em minha vida.

Gostaria de agradecer ao meu companheiro Gabriel, que jamais me negou apoio, carinho e incentivo. Obrigada por me aguentar tantas crises de estresse e ansiedade, Sem você do meu lado esse projeto não seria possível.

Sou grata a todos professores que contribuíram com a minha trajetória acadêmica, especialmente ao professor Dr. Gilberto Carrijo, responsável pela orientação do meu projeto. Obrigada por esclarecer tantas dúvidas e ser tão atencioso e paciente.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento do projeto de pesquisa, tornando possível a produção desta tese. Obrigada pelo incentivo, vocês fazem a diferença!

Enfim, agradeço a todos que convivi ao longo do meu processo, que me incentivaram e que certamente tiveram impacto na minha formação acadêmica.

“O temor do SENHOR é o princípio da sabedoria,
e o conhecimento do Santo a prudência.”

(Provérbios 9:10)

RESUMO

A previsão da taxa de chuva e a atenuação provocada por ela desempenha um papel essencial nas áreas de comunicações. Em outras palavras, prever a atenuação devido a precipitação pluviométrica não é uma tarefa simples de ser resolvida matematicamente, pois as variáveis que causam o fenômeno são frequentemente não lineares e apresentam comportamento complicados. Este projeto apresenta a previsão da atenuação da chuva no Brasil utilizando a Rede Neural Artificial (RNA). Dados pluviométricos de dez anos foram coletados a partir de medições realizadas em diferentes localizações geográficas. Os locais abrangem todos os cinco estados, representando todas as áreas geográficas do Brasil. A RNA foi treinada para prever a atenuação da chuva nesses locais usando os dados anuais de chuvas fornecidos de 2012 a 2021. Foram utilizados dois tipos de arquitetura de redes: rede MLP e rede LVQ, ambas com mesmo objetivo. Os resultados da atenuação da chuva fornecidos pela RNA foram comparados com os resultados fornecidos pelo modelo da União Internacional de Telecomunicações (ITU), que é um modelo bem estabelecido. Em termos de desempenho, mostram que a atenuação prevista da RNA está de acordo com a previsão do modelo ITU. Por outro lado, o treinamento da RNA resultante é uma ferramenta útil para engenheiros de comunicação para prever a atenuação da chuva dos anos subsequentes e resolver proativamente o problema de atenuação do sinal inerente à operação do caminho satélite acima de 10 GHz.

Palavras-chave: Atenuação da chuva, taxa de chuva, RNA, modelo ITU, rede MLP, rede LVQ.

ABSTRACT

Predicting the rate of rain and attenuation caused by it plays an essential role in the areas of communications. In other words, predicting attenuation due to rainfall is not a simple task to be solved mathematically, because the variables that cause the phenomenon are often nonlinear and have complicated behavior. This project is expected to predict rain attenuation in Brazil using the Artificial Neural Network (RNA). Ten-year rainfall data were collected from measurements performed in different geographical locations. The local covered all five states, representing all geographic areas of Brazil. RNA was trained to predict rain attenuation in these locations using annual rainfall data from 2012 to 2021. Two types of network architecture were used: Multilayer Perceptron Network (MLP) and Vector Quantization by Learning Network (LVQ), both with the same objective. The results of rain attenuation provided by RNA were compared with the results provided by the International Telecommunications Union (ITU) model, which is a well-established model. In terms of performance, they show that the predicted attenuation of RNA is in line with the forecast of the ITU model. On the other hand, the resulting RNA training is a useful tool for communication engineers to predict the attenuation of the rain of subsequent years and proactively solve the problem of signal attenuation inherent to the operation of the satellite path above 10 GHz.

Keywords: Rain attenuation, rain rate, RNA, ITU model, MLP network, LVQ network.

LISTA DE FIGURAS

Figura 1 -	Atenuação por absorção.....	16
Figura 2 -	Atenuação por espalhamento.....	16
Figura 3 -	Regiões Climáticas.....	20
Figura 4 -	Esquemático de um caminho Terra -Espaço oferecendo os parâmetros para ser inseridos no processo de previsão da atenuação	21
Figura 5 –	Esquema do neurônio biológico.....	26
Figura 6 –	Evolução das redes neurais.....	27
Figura 7 –	Esquema do Neurônio Artificial.....	28
Figura 8 –	Organização em camadas.....	29
Figura 9 –	Arquitetura FeedForward de camada simples.....	30
Figura 10 –	Arquitetura FeedForward de múltiplas camadas.....	30
Figura 11 –	Topologia do Multilayer Perceptron.....	35
Figura 12 –	Ilustração topológica da LVQ.....	36
Figura 13 –	Processos de treinamento da RNA para previsão da atenuação da chuva.....	49
Figura 14 –	Processos de treinamento da RNA para previsão da atenuação da chuva.....	51
Figura 15 –	Comparação ITU versus RNA.....	53
Figura 16 -	Divisão de cluster para arquitetura LVQ.....	54

LISTA DE GRÁFICOS

Gráfico 1 –	Comportamento da função ativação linear.....	32
Gráfico 2 –	Comportamento da função ativação sigmoide.....	32
Gráfico 3 –	Precipitação anual região Sudeste.....	39
Gráfico 4 –	Precipitação anual região Sul.....	40
Gráfico 5-	Precipitação anual região Nordeste.....	41
Gráfico 6 –	Precipitação anual região Centro Oeste.....	42
Gráfico 7 -	Precipitação anual região Norte.....	43

LISTA DE TABELAS

Tabela 1 -	Coefficiente para cálculo da atenuação específica.....	19
Tabela 2 -	Taxa de chuva.....	20
Tabela 3 -	Precipitação anual (mm) de algumas cidades selecionadas na região Sudeste.....	39
Tabela 4 -	Precipitação anual (mm) de algumas cidades selecionadas na região Sul.....	40
Tabela 5 -	Precipitação anual (mm) de algumas cidades selecionadas na região Nordeste.....	41
Tabela 6 -	Precipitação anual (mm) de algumas cidades selecionadas na região Centro Oeste.....	42
Tabela 7 -	Precipitação anual (mm) de algumas cidades selecionadas na região Norte.....	43
Tabela 8 -	Parâmetro geográficos de algumas cidades selecionadas região Sudeste.....	45
Tabela 9 -	Parâmetro geográficos de algumas cidades selecionadas região Sul.....	45
Tabela 10 -	Parâmetro geográficos de algumas cidades selecionadas região Nordeste.....	45
Tabela 11 -	Parâmetro geográficos de algumas cidades selecionadas região Centro Oeste.....	46
Tabela 12 -	Parâmetro geográficos de algumas cidades selecionadas região Norte.....	46
Tabela 13 -	Resultados da MLP.....	54
Tabela 14 -	Resultados da LVQ.....	54
Tabela 15 -	Faixas para as taxas de chuva que são excedidas em 0,01% por região do Brasil.....	55
Tabela 16 -	Faixas para as atenuações por região do Brasil.....	56

LISTA DE ABREVIATURAS E SIGLAS

RNA	Rede Neural Artificial
MLP	Perceptron Multicamadas
LVQ	Quantização Vetorial por Aprendizagem
INMET	Instituto Nacional de Meteorologia
ITU	União Internacional de Telecomunicações
ITU-R	União Internacional de Telecomunicações setor Radiocomunicação.
IEEE	Instituto de Engenheiros Elétricos e Eletrônicos
MSE	Erro Quadrático Médio

SUMÁRIO

1. INTRODUÇÃO.....	12
1.1 Considerações Preliminares.....	12
1.2 Objetivo.....	13
1.3 Estrutura da dissertação	13
2. EFEITOS E MODELOS DA ATENUAÇÃO POR CHUVAS	15
2.1 Introdução	15
2.2 Perdas devido à chuva.....	15
2.3 Fatores que influênciam na atenuação	17
2.4 Modelos para previsão da atenuação	18
2.5 Modelo ITU-R P. 618-13.....	19
2.6 Considerações Finais	24
3. REDES NEURAIS ARTIFICIAIS	25
3.1 Introdução	25
3.2 Redes Neurais	25
3.3 Uma breve história.....	26
3.4 Características Gerais das Redes Neurais.....	28
3.5 Arquiteturas de Rede Neurais Artificiais.....	29
3.6 Processos de aprendizagem	31
3.7 Funções de ativação	31
3.8 Algoritmo Backpropagation	34
3.9 Rede Multilayer Perceptron.....	35
3.10 Rede Learning Vector Quantization	36
3.11 Considerações Finais	37
4. MEDIDAS DE PRECIPITAÇÃO DA CHUVA.....	38
4.1 Introdução	38
4.2 Medidas do INMET	38
4.3 Precipitação Anual da chuva.....	38
4.4 Parâmetros geográficos.....	43
4.5 Parâmetros Geográficos.....	44
4.6 Considerações Finais	46

5. REDES NEURAIS PARA PREVISÃO DA ATENUAÇÃO.....	47
5.1 Introdução	47
5.2 Procedimento para a criação da RNA.....	47
5.3 Procedimentos para Teste Criado	50
5.4 Desempenho da previsão da RNA nas atenuações da chuva.....	51
5.5 Considerações Finais	56
6. CONCLUSÕES FINAIS	58
6.1 Introdução	58
6.2 Análise Final.....	58
6.3 Previsões Futuros.....	59
REFERÊNCIAS BIBLIOGRÁFICAS	60

1. INTRODUÇÃO

1.1 Considerações Preliminares

A chuva causa atenuação nas ondas eletromagnéticas através da absorção e o espalhamento do processo. Esse fenômeno é relativo à taxa e frequência de chuvas resultando em maior perda de caminho, limitando a área de cobertura e reduzindo assim o desempenho do sistema. Embora a União Internacional de Telecomunicações no setor Radiocomunicação (ITU-R) sintetizou uma abordagem meteorológica que prevê a atenuação da chuva, porém não obteve sucesso em algumas regiões como os climas tropicais, pois é baseado em dados coletados de regiões temperadas.

Existem vários métodos para prever a redução das chuvas em enlaces, nas quais são agrupados em duas classes: empíricos e físicos. As classes empíricas dependem de banco de dados de estações em diferentes locais dentro de uma determinada região, e as classes físicas tentam reproduzir o comportamento físico envolvido no processo de atenuação.

O método de previsão de atenuação de chuva atualmente recomendado pela ITU-R para enlaces é baseado em um modelo simplificado do campo de chuva que afeta o caminho de propagação. A suposição desses métodos de atenuação é que uma unidade de taxa de chuva uniforme equivalente pode simular chuva não uniforme ao longo do caminho de propagação.

Na previsão do caminho inclinado, dado na Recomendação ITU-R P. 618-13, fatores de redução horizontal e vertical são empregado para levar em conta a variabilidade espacial e temporal do campo de chuva. É importante fazer uma avaliação precisa da previsão de atenuação da chuva para um bom planejamento, visando o equilíbrio do compromisso entre disponibilidade de largura de banda e problemas de chuva provocando atenuação do sinal.

Esta dissertação visa estabelecer a comparação entre a atenuação da chuva prevista pelas redes neurais artificiais e ITU em diversas localidades no Brasil. Além disso, o estudo será de grande utilidade para entender as características da atenuação da chuva sobre essas regiões.

1.2 Objetivo

A necessidade de implementar modelos de atenuação provocada pelas chuvas que proporcione maior precisão para abranger várias regiões possíveis, e que possuam facilidade para implementação e exceda os limites inerentes ao uso de taxas de precipitação que se referem apenas a uma porcentagem do tempo, sendo uma das motivações deste projeto.

Outra motivação significativa foi encontrar uma solução para um problema existente na literatura, onde consiste na previsão da atenuação provocada pelas chuvas em enlaces convergentes, na qual é de grande relevância no cálculo da interferência em sistemas ponto e multiponto com frequências acima de 10 GHz.

Sendo assim, o principal objetivo realizar previsões da atenuação causadas pelas chuvas empregando redes neurais artificiais com dados de medições obtidas pelo Instituto Nacional de Meteorologia em diferentes regiões geográficas do território Brasileiro.

1.3 Estrutura da dissertação

Na introdução da dissertação, no *capítulo 1*, é apresentado o conceito da atenuação provocada pela chuva e quais causas provoca no sinal. Destaca-se ainda a importância do seguinte estudo para o projeto de enlace de comunicações em especial no Brasil, onde possuem precipitações diversas em seu território. Apresenta se também o objetivo principal da dissertação que utiliza dados de medições e seu tratamento para o cálculo da atenuação.

O *capítulo 2* apresenta uma descrição detalhada dos efeitos causados pela chuva na transmissão do sinal, a existência de vários modelos da atenuação existentes na literatura. Descreve se é caracteriza o modelo matemático do ITU- R, um dos mais utilizados nos projetos de enlace de comunicações.

O *capítulo 3* é dedicado a uma revisão de vários conceitos relacionados à área de redes neurais artificiais e necessários para o desenvolvimento desse trabalho, como por exemplo, a rede Perceptron Multicamadas e a rede Quantização de Vetores de Aprendizagem.

O *capítulo 4* apresenta os detalhes dos dados utilizados no projeto, tais como a precipitação da chuva em diversas localidades do Brasil, detalhando a importância das medições da taxa de precipitação e parâmetros geográficos para auxílio no cálculo da atenuação provocada pela chuva.

O desenvolvimento das redes neurais artificiais para a previsão da atenuação são apresentados no *capítulo 5*. Nesse capítulo são feitas também considerações sobre a estratégia utilizada para o processamento das medidas, além dos procedimentos e ajustes de algumas medidas. Além disso apresenta os resultados obtidos e uma pré análise dos dados coletados, para a consideração da atenuação provocada pela chuva.

Por fim, no *capítulo 6* são apresentadas conclusões a partir dos dados obtidos, as contribuições dessa dissertação e recomendações para trabalhos futuros.

Capítulo 2

2. EFEITOS E MODELOS DA ATENUAÇÃO POR CHUVAS

2.1 Introdução

Avaliar o impacto da água da chuva no projeto do sistema telecomunicações requer um conhecimento estatísticos de atenuação em frequências específicas de interesse para cada localização de terminal terrestre. Os métodos de modelagem e previsão devem ser usados para realizar uma melhor estimativa da atenuação esperada para cada local.

Sobre o último anos, grandes esforços têm sido empreendidos para desenvolver técnicas para a previsão da atenuação da chuva de trajetória para um determinado local e frequência e a disponibilidade de medições com base de dados para a validação e refinamento dos modelos de previsão.

Este capítulo demonstra uma das técnicas de previsão da atenuação provocada pela chuva mais promissora e utilizada em projeto de comunicações. O modelo da ITU-R calcula a atenuação para taxa de precipitação de chuva de 0,01% do tempo. Para as demais percentagens do tempo, utiliza se uma extrapolação.

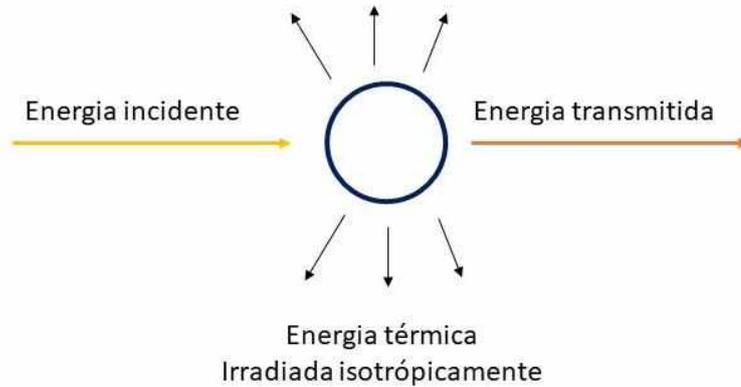
2.2 Perdas devido à chuva

A transmissão dos sinais em frequências acima de 10 GHz é afetada por efeitos atmosféricos, na qual gera limitações à área de cobertura dos links de comunicações principalmente nas bandas Ku e Ka. A presença de hidrometeoros pode ocasionar uma atenuação que prejudica a confiabilidade e o desempenho do sinal. Os fatores que mais limitam a propagação são a absorção e o espalhamento.

À proporção que a frequência aumenta, o comprimento de onda do sinal propagado se aproxima do tamanho da gota de chuva, causando um aumento na atenuação do sinal. As gotas identificam como um dielétrico imperfeito para o campo elétrico incidente, resultando nos fatores nas quais limitam a propagação do sinal [1].

A absorção é a diminuição na amplitude do vetor campo elétrico da onda provocada pela transformação irreversível da energia da onda no caminho da propagação, isto é, quando a gota atinge a temperatura do meio, a energia será re-irradiada, causada pela dissipação térmica [2], como mostra a Figura 1.

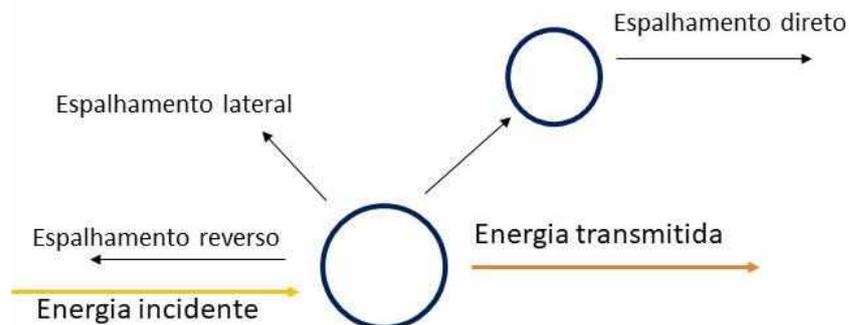
Figura 1 – Atenuação por absorção.



Fonte: O autor.

O espalhamento é a maneira como a energia de uma onda é dispersa em direções por causa da interação com o meio não homogêneo, ou seja, a modificações sofridas pelas ondas para atender as condições de contorno de cada gota de chuva [2]. Sendo assim, não há perda de energia e podendo ser em qualquer direção, conforme a Figura 2 os viáveis espalhamentos.

Figura 2 – Atenuação por espalhamento



Fonte: O autor.

2.3 Fatores que influênciam na atenuação

A gota em queda assume a forma de um oblato esferoide inclinado em relação à direção da queda, em contraste com sua forma esférica inicial durante a formação da precipitação [3]. O eixo maior da seção da reta da gota é mais orientado horizontalmente, a razão pela qual uma onda com polarização horizontal linear sofre mais atenuação do que uma onda com polarização vertical linear.

A atenuação de uma onda polarizada circularmente é independente do ângulo da gota, porque a onda é composta por duas ondas polarizadas linearmente. O tamanho das gotas, cujo diâmetro varia entre 0,01 e 6 mm, é um fator significativo a ser considerado na estimativa da atenuação da chuva. As gotas evaporam rapidamente em diâmetros inferiores a 0,01 mm. Para diâmetros maiores que 6 mm, o tensor superficial é insuficiente para manter o coeso, e a gota fragmenta-se em gotas menores [3].

Para previsão da atenuação da chuva em frequências de até 40 GHz em climas temperados utiliza-se a distribuição de gota de Laws e Parsons. A distribuição de pequenas gotas, relevante na faixa de ondas milimétricas, é melhor descrita pela distribuição negativa de Marshall exponencial Palmer [3]. Desta forma, recomenda-se a utilização de mais de uma distribuição nesta faixa de frequências, dependendo dos tamanhos das gotas consideradas.

Em climas tropicais, quando as taxas de precipitação são altas, uma distribuição log normal descreve bem a distribuição das gotas. Este modelo produz valores de atenuação específicos maiores que as distribuições Law e Parsons, e seu uso nestas condições é recomendado para aplicações com frequências acima de 30 GHz. A velocidade terminal das gotas, que Gunn e Kinzer atrelaram ao tamanho das gotas, é dependente da densidade do ar, que varia com a altura. Devido à resistência proporcionada pelo ar, que provoca o fracionamento das gotas seu número aumenta à medida que a chuva diminui, mas o teor de água permanece o mesmo. Com a atenuação de um sinal que passa por uma área inundada é determinada principalmente pela quantidade de água presente, a atenuação específica varia com a altura abaixo da linha da chuva [2].

A taxa de precipitação é calculada pelo diâmetro e velocidade terminal das gotas, e é expressa em milímetros por hora. A precisão da distribuição da taxa de precipitação é fundamental para o desenvolvimento de modelos de previsão de chuva [4].

É necessário entender a distribuição espacial das chuvas para poder prever a atenuação por chuvas. A chuva é uma coleção de gotículas de água que se estendem horizontalmente por

vários quilômetros e cujo limite superior é conhecido como altitude da chuva. A célula de chuva tem um núcleo onde ocorre a precipitação mais intensa. Seu diâmetro total varia inversamente com a taxa de precipitação [5]. Medições de radar mostram que o diâmetro das células de chuva intensa fica tipicamente entre 2 a 5 quilômetros.

É preciso ficar atento à previsão de atenuação da chuva. Outro fator que influencia na atenuação da chuva é a temperatura, que afeta o índice de refração da água. Enquanto a parte real do índice refração da água diminui à medida que a temperatura aumenta, a parte imaginária mostra um aumento entre 10 e 100 GHz. Como resultado, a atenuação de um sinal que passa por uma chuva de células também mostrará um pico de 10 a 100 GHz [2-5].

Para dar conta da falta de uniformidade espacial na taxa de precipitação, a maioria dos modelos de previsão usa uma distribuição pontual acumulativa das taxas de precipitação em um ponto no caminho e fatores de correção. Sempre que possível, devem ser usados dados de taxas de precipitação locais. Se não possuir essas informações, precisará usar valores obtidos em regiões climaticamente semelhantes. O ITU-R introduz o conceito de região climática, que é definida específica nas taxas de precipitação por porcentagem de tempo. No entanto, as medições feitas em regiões tropicais mostram diferenças significativas em relação aos valores recomendados pelo ITU-R para este tipo de clima.

Por fim, no cálculo da atenuação da chuva, deve se levar em consideração o comprimento do enlace (para enlaces terrestres) e o ângulo de elevação (para enlaces satélites), pois esses parâmetros são dependentes do comprimento do enlace que efetivamente está sendo atravessado pela célula de chuva.

2.4 Modelos para previsão da atenuação

Existem muitos modelos para prever a atenuação da chuva, e repleto de trabalhos relacionados a área, cada um com seu desempenho. Um dos modelos mais conhecidos e têm mostrado um melhor desempenho é o modelo ITU-R P. 618-13 (*Propagation data and prediction methods required for the design of Earth space Telecommunication system*) [6]. Este modelo é o modelo mais confiável, apesar de possuir uma precisão razoável em certas localidades do mundo.

Sua limitação está ligada com a utilização de apenas um valor de taxa de precipitação 0,01% [6] do tempo para retratar o regime da chuva na região que se deseja e a pouca precisão quando empregue em alguns climas presentes no território Brasileiro.

O método para previsão da atenuação da chuva é fundamentado na relação entre a taxa de precipitação R (mm/h) e a atenuação específica γ_R (dB/km), definida com base na modelagem da estrutura chuva (tamanho das gotas de chuva) [6]. Caso a variação da taxa de precipitação no decorrer de um dado local é conhecida, sua atenuação devido à chuva no enlace pode ser obtida integrando a atenuação específica sobre o comprimento do caminho.

2.5 Modelo ITU-R P. 618-13

O modelo ITU-R baseado no modelo DAH (Dissanayake, Haidara, Allnut) é certamente o modelo mais preciso atualmente em uso, onde a atenuação específica (γ_R) em 1km é dada por [7]:

$$\gamma_R = k \cdot (R_{0,01\%})^\alpha \text{ dB/km} \quad (1)$$

Onde,

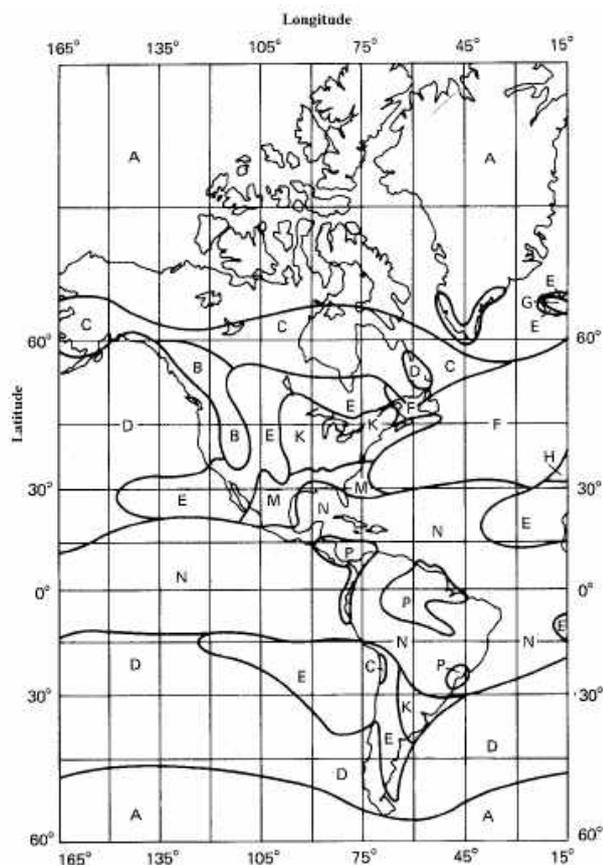
- k e α são coeficientes de acordo com o tipo de polarização da onda, conforme a Tabela 1 [3],
- $R_{0,01}$ é o índice pluviométrico relativo a 0,01% do tempo em mm/h. Esses índices podem varia de 10% a 0,001%, conforme na Figura 3 e Tabela 2 [8].

Tabela 1 – Coeficiente para cálculo da atenuação específica.

Frequência (GHz)	K_H	K_V	α_H	α_V
4	0.000650	0.000591	1.211	1.075
6	0.00175	0.00155	1.308	1.265
8	0.00454	0.00395	1.327	1.310
10	0.0101	0.00887	1.276	1.264
12	0.0188	0.0168	1.217	1.200
20	0.0751	0.0691	1.099	1.065
30	0.187	0.167	1.021	1.000
40	0.350	0.310	0.939	0.929
50	0.536	0.479	0.873	0.868

Fonte: García, 2003.

Figura 3 - Regiões Climáticas.



Fonte: Alencar, 2008.

Tabela 2 – Taxa de chuva.

Porcentagem do tempo (%)	Valores da taxa de distribuição de chuvas (mm/h)													
	A	B	C	D	E	F	G	H	J	K	L	M	N	P
1,0	-	1	-	3	1	2	-	-	-	2	-	4	5	12
0,3	1	2	3	5	3	4	7	4	13	6	7	11	15	34
0,1	2	3	5	8	6	8	12	10	20	12	15	22	35	65
0,03	5	6	9	13	12	15	20	18	28	23	33	40	65	105
0,01	8	12	15	19	22	28	30	32	35	42	60	63	95	145
0,003	14	21	26	29	41	54	45	55	45	70	105	95	140	200
0,001	22	32	42	42	70	78	65	83	55	100	150	120	180	250

Fonte: Alencar, 2008.

A recomendação ITU-R Rec. 618-13 “*Propagation data and prediction methods required for the design of Earth space Telecommunication system*” utiliza a taxa de chuva no nível de probabilidade 0,01% para estimativa de atenuação [6]. O modelo é derivado com base na

distribuição log-normal, e a intensidade da chuva e a distribuição de atenuação usualmente estão conforme com a distribuição log-normal. Possuem uma falta de semelhança quando se trata das direções das chuvas que pode ser horizontal e vertical e isso compromete na previsão.

Este modelo se aplica a faixa de frequência de 4 a 55 GHz e uma faixa de probabilidade percentual de 0,001% à 5% [6]. As estatísticas de atenuação da chuva ao longo prazo na faixa de frequência são estimadas a partir das trajetórias inclinadas em um determinado local de acordo com a Figura 4. Os seguintes parâmetros são apresentados neste processo [6]:

$R_{0,01}$: taxa de precipitação pontual para o local para 0,01% de um ano médio (mm/h)

h_s : altura acima do nível do mar da estação terrena (km)

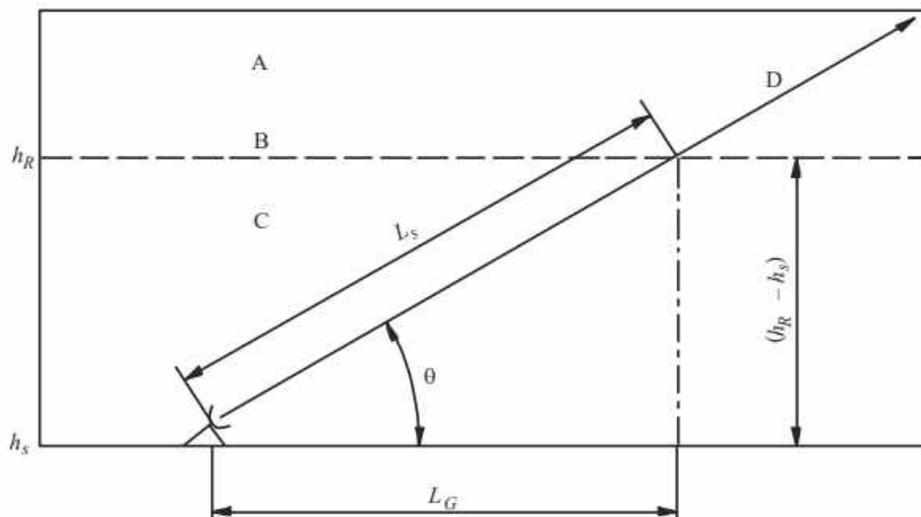
θ : ângulo de elevação ($graus$)

φ : latitude da estação terrestre ($graus$)

f : frequência (GHz)

R_e : raio efetivo da Terra ($8500 km$)

Figura 4 – Esquemático de um caminho Terra- espaço utilizando os parâmetros para ser inserido no processo de previsão da atenuação.



Fonte: ITU – R 618.13, 2017.

A – Precipitação congelada

B- Altura da chuva

C – Precipitação líquida

D – Caminho Terra-espaço

Passo 1 – Determine a altura da chuva h_R , conforme indicado na recomendação ITU- R P. 839.

Passo 2 – Calcule o comprimento do caminho inclinado L_S abaixo da altura da chuva a partir de:

$$L_S = \frac{(h_R - h_S)}{\sin \theta} \text{ km} \quad (2)$$

Para $\theta < 5^\circ$, a seguinte fórmula é usada

$$L_S = \frac{2(h_R - h_S)}{\left(\sin^2 \theta + \frac{2(h_R - h_S)}{R_e}\right)^{1/2} + \sin \theta} \text{ km} \quad (3)$$

Passo 3 – Calcule a projeção horizontal, L_G do comprimento do caminho inclinado de

$$L_G = L_S \cos \theta \text{ km} \quad (4)$$

Passo 4 – Obtenha a taxa de precipitação, $R_{0,01}$ de um ano médio (com uma integração tempo de 1 minuto). Se esta estatística de longo prazo não for capaz de ser obtida de fontes de dados locais, então uma estimativa pode ser obtida a partir dos mapas de taxa de precipitação fornecidos na Recomendação ITU-R P.837. Se $R_{0,01}$ for igual a zero, a atenuação de chuva prevista é zero para qualquer porcentagem de tempo e as etapas a seguir não são requeridos.

Passo 5 - Obtenha a atenuação específica, γ_R utilizando os coeficientes dependentes da frequência fornecidos em Recomendação ITU-R P. 838 e a taxa de precipitação $R_{0,01}$, determinada a partir do passo 4, usando:

$$\gamma_R = k (R_{0,01})^\alpha \text{ dB/km} \quad (5)$$

Passo 6 - Calcule o fator de redução horizontal, $r_{0,01}$ para 0,01% do tempo:

$$r_{0,01} = \frac{1}{1 + 0.78 \sqrt{\frac{L_G \gamma_R}{f}} - 0.38 (1 - e^{-2L_G})} \quad (6)$$

Passo 7 - Calcule fator de ajuste vertical, $v_{0,01}$, para 0,01% do tempo:

$$\xi = \tan^{-1} \left(\frac{h_R - h_S}{L_G r_{0,01}} \right) \text{ (graus)} \quad (7)$$

Para $\xi > \theta$,

$$L_R = \frac{L_G r_{0,01}}{\cos \theta} \text{ km} \quad (8)$$

Senão,

$$L_R = \frac{(h_R - h_S)}{\sin \theta} \text{ km} \quad (9)$$

Se $|\varphi| < 36^\circ$,

$$\chi = 36 - |\varphi| \text{ (graus)} \quad (10)$$

Senão,

$$\chi = 0 \text{ (graus)} \quad (11)$$

$$v_{0,01} = \frac{1}{1 + \sqrt{\sin \theta} (31(1 - e^{-(\theta/(1+\chi))}) \frac{\sqrt{L_R \gamma_R}}{f^2} - 0.45)} \quad (12)$$

Passo 8 – O comprimento efetivo do caminho

$$L_E = L_R v_{0,01} \text{ km} \quad (13)$$

Passo 9 – A atenuação prevista excedida para 0,01% de um ano médio é obtida de:

$$A_{0,01} = \gamma_R L_E \text{ dB} \quad (14)$$

Passo 10 – A atenuação estimada a ser superada para outras porcentagens de um ano médio, na faixa 0,001% a 5%, é determinado a partir da atenuação a ser excedida para 0,01% para um ano médio:

$$\text{Se } p \geq 1\% \text{ ou } |\varphi| \geq 36^\circ: \quad \beta = 0 \quad (14)$$

$$\text{Se } p < 1\% \text{ e } |\varphi| < 36^\circ \text{ e } \theta \geq 25^\circ \quad \beta = -0.005(|\varphi| - 36) \quad (15)$$

$$\text{De outra forma:} \quad \beta = -0.005(|\varphi| - 36) + 1.8 - 4.25 \text{ si } n\theta \quad (16)$$

$$A_P = A_{0,01} \left(\frac{p}{0,01} \right)^{-(0.655+0.033 \ln(p)-0.045 \ln(A_{0,01})-\beta(1-p)\text{si } n\theta)} \text{ dB} \quad (17)$$

2.6 Considerações Finais

Nesse presente capítulo destina-se a fundamentação teórica sobre o efeito da chuva nos enlaces de comunicações. O efeito das chuvas na transmissão é de suma relevância conhecido como a razão principal da atenuação em frequências acima de 10 GHz.

Após a Segunda Guerra Mundial começaram estudos e pesquisas para determinar a atenuação das chuvas. Através disso, desenvolveram estudos mais refinados utilizando tecnologias atuais, avaliando os efeitos das causas que contribuem para essa perda devido à chuva como por exemplo os tamanhos e formatos das gotas, taxas de precipitação, refração, espalhamento, frequência e a polarização do sinal.

A Recomendação ITU-R P. 618-13 trata de dados de propagação e métodos de previsão necessário para o projeto do espaço terrestre em sistema de telecomunicações. Esse método fornece uma estimativa das estatísticas de longo prazo da atenuação devido à chuva. Quando comparadas as estatísticas medidas com a previsão, possuem uma grande variabilidade ano a ano nas estatísticas de precipitação.

Capítulo 3

3. REDES NEURAIS ARTIFICIAIS

3.1 Introdução

A necessidade de controlar certas incertezas é um tema central na relação do homem com a natureza e seus eventos futuros, e as possíveis implicações das decisões a serem tomadas. Para lidar com essas questões, é necessário determinar a probabilidade de sucessos e fracassos ao longo do tempo.

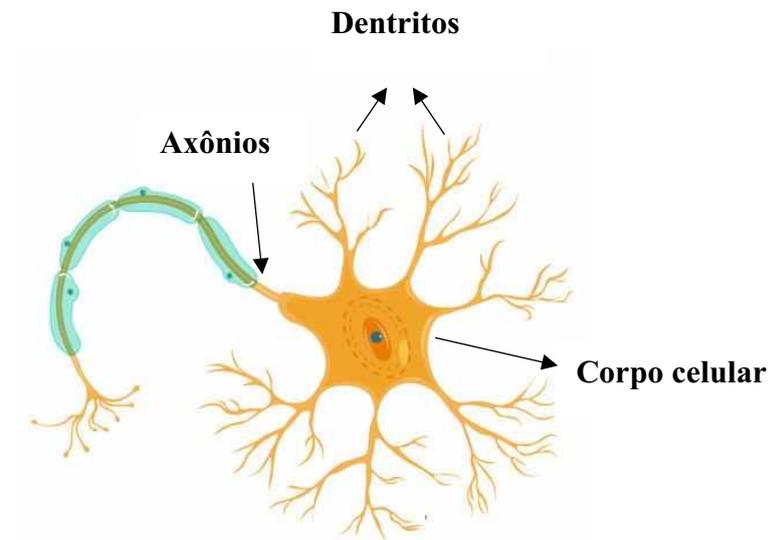
A escolha das redes neurais artificiais como técnica nesse projeto, decorreu ao fato de sua aplicação nas diversas áreas das telecomunicações incluindo trabalhos de previsão e análise. O projeto da rede neural requer que vários fatores sejam considerados para alcançar níveis aceitáveis de desempenho, cada um dos quais os projetistas de rede têm suas próprias ideias são aqueles com pequeno erro, curto tempo de treinamento, baixa sensibilidade e baixo número de neurônios. Se a rede estiver bem treinada, ela será capaz de reconhecer essas condições intermediárias bem treinadas, ou seja, a rede terá a capacidade de generalizar.

3.2 Redes Neurais

A rede neural artificial é uma computação projetada para processar dados de maneira semelhante ao cérebro humano. O cérebro é o principal órgão do sistema nervoso que controla nosso corpo, onde está relacionado com a inteligência, linguagem, consciência, memória, entre outros. Além disso, ele é capaz de processar informações dos sentidos e de outras estruturas cerebrais, iniciando movimentos e influenciando o comportamento emocional.

O sistema nervoso consiste em um conjunto complexo de células, chamado neurônios, desempenhando papel vital na determinação de como o corpo humano funciona e se comporta. Os neurônios são constituídos basicamente por três estruturas: um corpo celular, dendritos e axônios [9], conforme mostrado na Figura 5.

Figura 5 -Esquema do neurônio biológico.



Fonte: O autor.

Onde,

- **Corpo celular** - região onde se encontra o núcleo, é o local onde ocorre o metabolismo celular.
- **Dendritos** – ramificações presentes no corpo celular que recebem os impulsos nervosos.
- **Axônio** – prolongamento do neurônio por onde os impulsos nervosos são levados a outro neurônio ou outro tipo de célula.

Nas redes neurais artificiais a ideia é processar informações com base nas organizações dos neurônios do cérebro humano, fazendo que seja capaz de aprender e realizar decisões com base no aprendizado. Desse modo, uma rede neural pode ser representada como um esquema de processamento capaz de armazenar conhecimento baseado na aprendizagem e disponibilizar esse conhecimento para aplicações essenciais [10].

3.3 Uma breve história

Em 1943, o neurofisiologista Warren McCulloch e o matemático Walter Pitts escreveram um artigo sobre como os neurônios seriam capazes de funcionar e para isso, modelaram uma

rede neural simples utilizando circuitos elétricos. Eles criaram um modelo computacional baseado em matemáticas e algoritmos denominados lógica de limiar [11].

No ano de 1949, o biólogo e psicólogo Donal Hebb escreveu um livro chamado *The Organization of Behavior* que ampliava as teorias de que o condicionamento psicológico estava presente em qualquer parte dos animais, pelo fato de que esta é uma propriedade de neurônios individuais, por isso 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 [12].

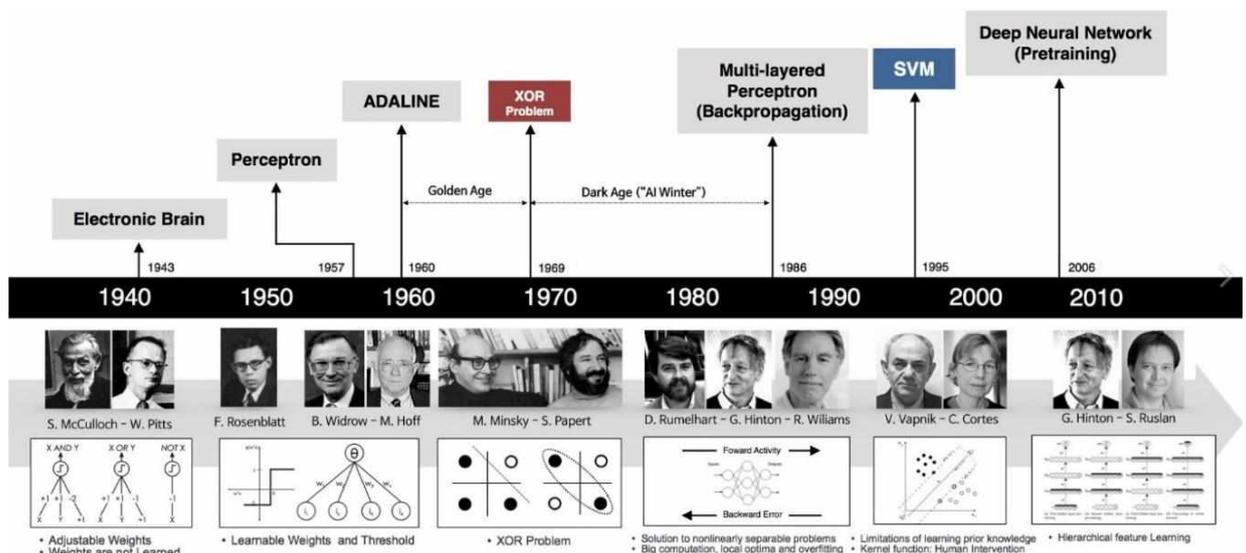
A partir disso, vários outros pesquisadores, motivados com as novas descobertas, voltaram se para este ramo de pesquisa.

Nas décadas de 1950 e início de 1960, surgiram cada vez mais arquiteturas de redes neurais, como a Perceptron, Adaline e Madaline, mas lamentavelmente diminuiu o desenvolvimento devido às limitações dos equipamentos eletrônicos da época [13].

Somente no início da década de 1980 apareceram novos trabalhos acadêmicos e implantações de redes neurais. Em 1987, realizou se a primeira conferência internacional sobre o tema organizado pelo Instituto de Engenheiro Elétricos e Eletrônicos (IEEE), onde obteve mais de 1800 pesquisadores. Foi nessa época que surgiram muitas ideias importantes apareceram como a redes multicamadas e técnicas de BackPropagation, que eram mais lentas, mas produziram resultados mais precisos [14].

A partir destes acontecimentos, muitas instituições formaram institutos de pesquisa e programas de educação em neuro computação. Na Figura 6, mostra se os marcos na evolução da Inteligência Artificial.

Figura 6 – Evolução das redes neurais.

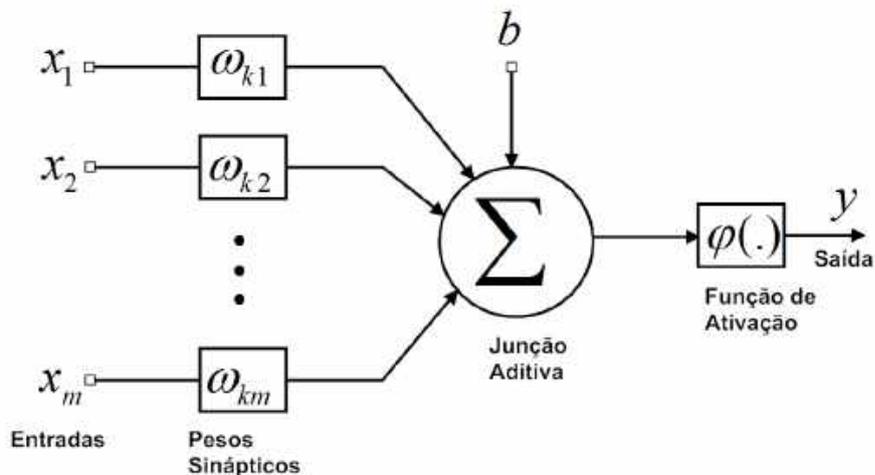


Fonte: Silva, 2010.

3.4 Características Gerais das Redes Neurais

A rede neural é composta por diversas unidades de processamento, que são conectadas por canais de comunicação associados a pesos específicos. Essas unidades operam apenas sobre seus dados locais, que são entradas recebidas por sua conexão. O desempenho inteligente de uma rede neural surge das interações entre as unidades de processamento. A estrutura na Fig. 7 mostra um neurônio artificial, onde suas entradas equivalem aos dendritos, um somador que equivale ao núcleo e concentra toda a informação, e tem uma saída que transmite um sinal para um determinado fim ou para outro perceptron [16].

Figura 7 – Esquema de Neurônio Artificial.



Fonte: Chauvin, 1995.

Suponhamos que tenha sinais de entrada X_1, X_2, \dots, X_p que são ponderados pelos pesos w_1, w_2, \dots, w_p com b denominado *bias* sendo todos agrupados pela função aditiva [17].

Existem vários modelos de redes neurais, nas quais possui determinada regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem por meio de exemplos [17].

A equação abaixo é uma combinação linear de pesos e entradas chamada de atividade pré sináptica, dada por: (1)

$$I_k = \sum_{i=1}^m w_{ki} x_i \quad (18)$$

A atividade pós sináptica é dada pelo funcional:

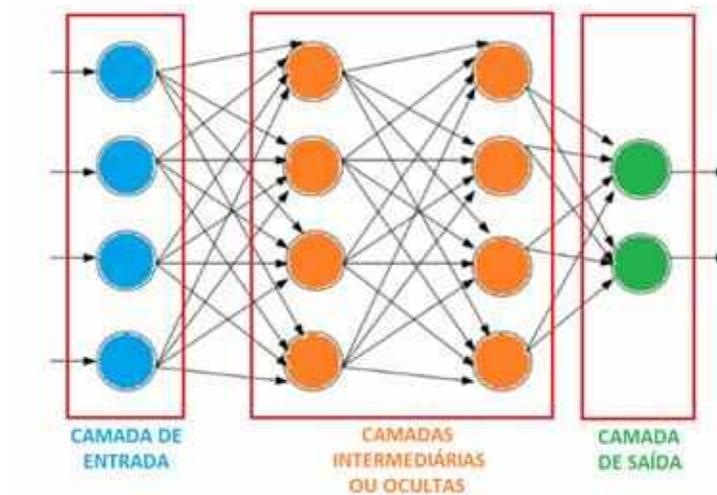
$$y = \varphi (I_k, w_k) \quad (19)$$

Onde φ pode assumir diversas formas, como funções lineares e não lineares [17].

3.5 Arquiteturas de Rede Neurais Artificiais

As arquiteturas neurais são geralmente organizadas em camadas, onde as unidades podem ser conectadas às unidades nas camadas subsequentes [16].

Figura 8 – Organização em camadas.



Fonte: Silva,2010.

As camadas são divididas em três grupos [18]:

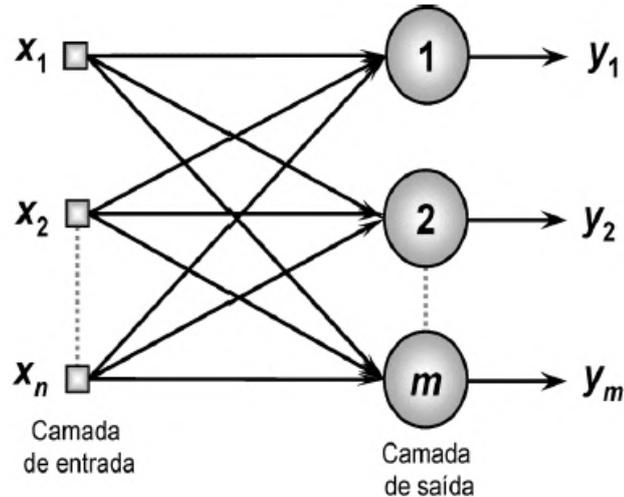
- **Camada de entrada:** onde os padrões são apresentados à rede;
- **Camada intermediárias ou ocultas:** é o local onde ocorre a maior parte do processamento, são conhecidos como extratores de características.
- **Camada de saída:** local onde é apresentado o resultado final.

As arquiteturas mais comuns das RNAs são:

- **FeedForward de Camada Simples:** Nesta arquitetura, a camada de entrada estão interligadas um ou mais neurônios que irão gerar a resposta final. São utilizadas em problemas

de classificação de padrões e filtragem. Os tipos de redes associados a essa arquitetura são as redes Perceptron e Adaline [19].

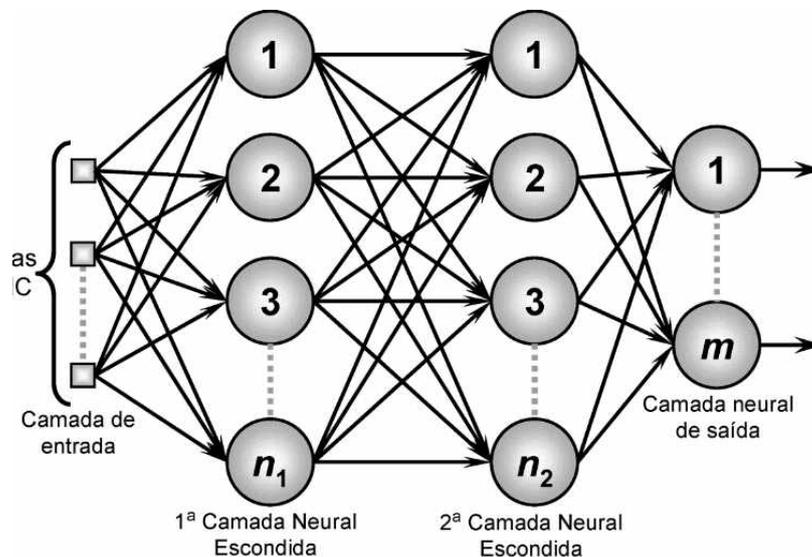
Figura 9 - Arquitetura FeedForward de camada simples.



Fonte: Hornik, 1995.

- **FeedForward de Camadas Múltiplas:** São composta por uma ou mais camadas ocultas. São utilizadas em problemas de aproximação de funções, classificação de padrões, otimização, entre outras aplicações. Os tipos de redes associados a essa arquitetura são as redes Perceptron Multicamadas e redes de base radial [19].

Figura 10 – Arquitetura FeedForward de Múltiplas camadas.



Fonte Hornik, 1995.

3.6 Processos de aprendizagem

O processo de aprendizagem é parte do algoritmo onde são definidas regras para a solução de um problema de aprendizado, isto é, ocorrem diversas mudanças significativas nas sinapses dos neurônios, isso acontece conforme a ativação dos neurônios [20].

Outro fator importante é a forma como a RNA se relaciona com o ambiente. Neste caso, existem os seguintes paradigmas de aprendizagem [20]:

- **Supervisionado:** a rede trabalha com um conjunto de entradas padronizadas com seus respectivos padrões de saída, onde ocorrem ajustes nos pesos sinápticos até que o erro entre os padrões de saída atingidos possua um valor esperado.
- **Não supervisionados:** a rede lida com dados de modo a apontar algumas características dos conjuntos de rede, com isso seu aprendizado é constituído.
- **Híbrido:** a rede sucede tanto na aprendizagem supervisionado quanto na não supervisionado, onde uma camada aplica se um tipo e na outra camada outro tipo.

3.7 Funções de ativação

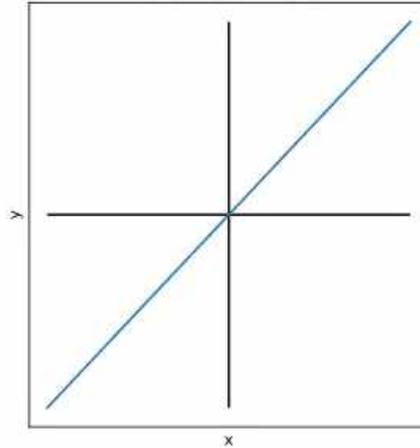
O processamento em cada neurônio é realizado através do que chamamos de função de ativação. A escolha das funções de ativação da rede neural é de grande importância, pois definem a aparência dos dados de entrada. Algumas dessas funções de ativação são demonstradas abaixo [21]:

3.7.1 Função linear

Essa função é mais comum, pois não altera a saída de um neurônio e utilizada nas camadas de saída em redes neurais de regressão. Pode se definir a função como:

$$f(x) = ax \quad (20)$$

Gráfico 1: Comportamento da função ativação linear.



Fonte: Silva, 2010.

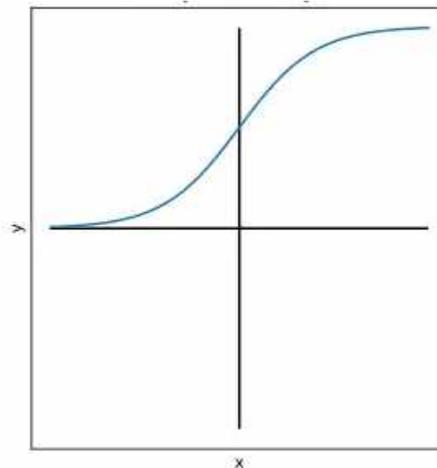
Dessa forma, a função linear pode ser ideal para trabalhos simples, onde a interpretabilidade é altamente pretendida.

3.7.2 Função sigmóide

A função sigmóide amplamente utilizada com propagação positiva (Feedforward), onde tem a necessidade de obter apenas números positivos na saída e em redes com sinais contínuos. Pode se definir a função como:

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (21)$$

Gráfico 2: Comportamento da função ativação sigmoide.



Fonte: Silva, 2010.

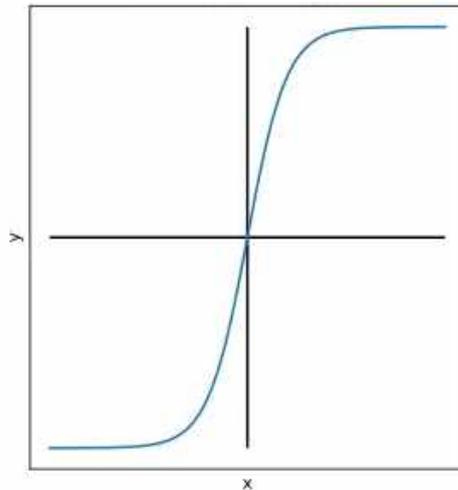
Esta função tenta levar o valor de Y ao extremo, onde é muito pretendida quando for classificar os valores de uma classe.

3.7.3 Função Tangente Hiperbólica

A função tangente hiperbólica mais conhecida como ativação TanH, possui uso em redes neurais cujas saída precisam ser entre -1 a 1. Essa função é uma versão escalonada da sigmóide. Pode se definir a função como:

$$\tanh(x) = \frac{2}{(1 + e^{-2x}) - 1} \quad (22)$$

Gráfico 3: Comportamento da função ativação TanH.



Fonte: Silva, 2010.

Assim, a função TanH soluciona os problemas dos valores, sendo todos do mesmo sinal, as outras propriedades são exatamente da função sigmóide.

As redes neurais artificiais podem utilizar várias outras funções de ativação. A escolha da função depende de que tipo de RNA e o problema que será usado para ser resolvido

3.8 Algoritmo Backpropagation

O algoritmo Backpropagation trabalha com multicamadas e resolve problemas “não linearmente separáveis”, ou seja, não pode separar em duas classes distintas no eixo cartesiano bidimensional apenas traçando uma reta. Trata-se de um algoritmo utilizando treinamento supervisionado, e através do erro calculado, o algoritmo corrige os pesos em todas as camadas, partindo da saída até atingir a entrada [22].

O ajuste dos pesos sinápticos é relativamente simples, pois os valores esperados e obtidos na unidade de saída são conhecidos, porém para as unidades na camada intermediária, o processo não é simples. Os pesos de um certo neurônio na camada intermediária devem ser ajustados proporcionalmente ao erro da unidade de processamento a qual está conectado [22].

Aplica-se a correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, sendo i o índice do respectivo nó de entrada do neurônio j , tendo como base a direção contrária do gradiente local da superfície de erro $\varepsilon (w_{ji}(n))$ relativo aos pesos sinápticos, mesmo quando o neurônio j esteja em uma camada escondida, e, portanto, não haja erro local explícito no neurônio em questão [23].

Portanto, possuem a capacidade de distinguir duas etapas no processo de aprendizagem do backpropagation. O estágio da forward, onde a entrada é propagada entre as camadas de rede, desde a camada de entrada até a camada de saída e a fase backward onde o erro se propaga na direção oposta ao fluxo de entrada [23].

O algoritmo backpropagation é constituído de duas etapas: propagação e retropropagação. Na etapa de propagação (forward) um conjunto de padrões é executado na camada de entrada e a resposta desta é propagada como entrada na camada subsequente. Isto implica a propagação dentro da rede, até que produzir um conjunto de saída com resposta atual da rede [24].

Na etapa de retropropagação, os pesos sinápticos são ajustados da camada de entrada até a camada de saída. A resposta atual da rede é subtraída de uma resposta desejada (target), gerando um sinal de erro. Este sinal é retropropagado através da rede no sentido contrário ao sinal funcional. Os pesos são ajustados para fazer com que a resposta atual da rede se aproxime à resposta desejada.

3.9 Rede Multilayer Perceptron

A rede multilayer perceptron (MLP) é uma generalização da rede perceptron, é aplicada em desempenho de tarefas de reconhecimento de voz, reconhecimento de imagem, classificação de padrões e controle. É uma rede onde utilizada para treinamento o algoritmo de retropropagação (Backpropagation), que se baseia na aprendizagem por correções de erros [25].

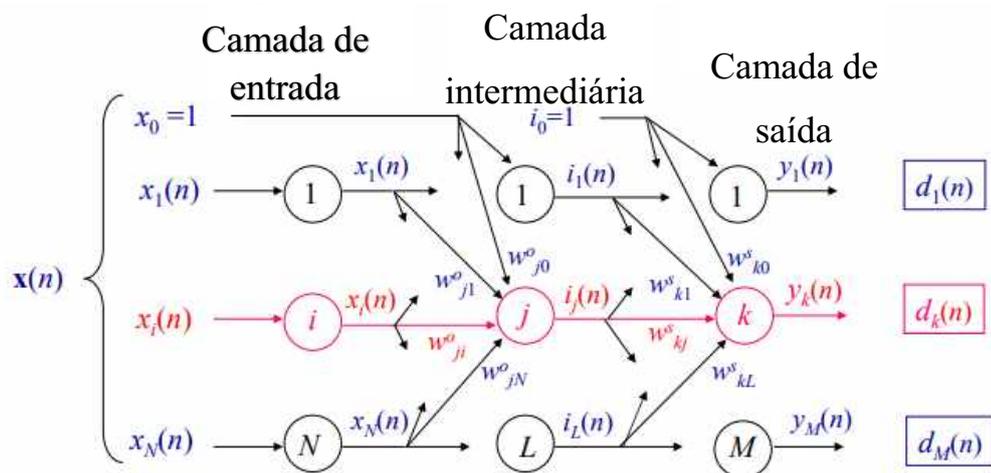
O treinamento supervisionado de uma MLP empregando a backpropagation consiste em duas etapas, onde na primeira etapa os padrões são apresentados às unidades da camada de entrada e, a partir dessa camada as unidades computam as repostas que é estabelecida na camada de saída. Já na segunda etapa, é propagada a partir da camada de saída até a entrada, os pesos de conexão das unidades das camadas internas são alterados usando a regra delta generalizada [25]. Podendo ser definida como:

$$w_{ji}(n+1) = w_{ji}(n) - \eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (23)$$

A MLP é formada de três partes, conforme a Figura 11:

- *Camada de entrada (input layer)*: constituída de um conjunto de unidades sensoriais. É responsável a propagação das informações de entrada para camada subsequente.
- *Camada intermediária ou escondidas (hidden layers)*: constituída de uma ou mais camadas ocultas. É responsável por transmitir as informações por meio das conexões entre as unidades de entrada e saída.
- *Camada de saída*: constituído por neurônios computacionais e fornecem a resposta.

Figura 11– Topologia do Multilayer Perceptron.



Fonte: Hausson, 1995.

Onde,

$i_j(n)$ = valor de saída do neurônio j da camada intermediária por $x(n)$

$y_k(n)$ = valor de saída do neurônio k da camada intermediária por $x(n)$

$d_k(n)$ = valor de saída desejado do neurônio k correspondente a $x(n)$

w_{ji}^o e w_{kj}^s = valor de saída desejado do neurônio k correspondente a $x(n)$

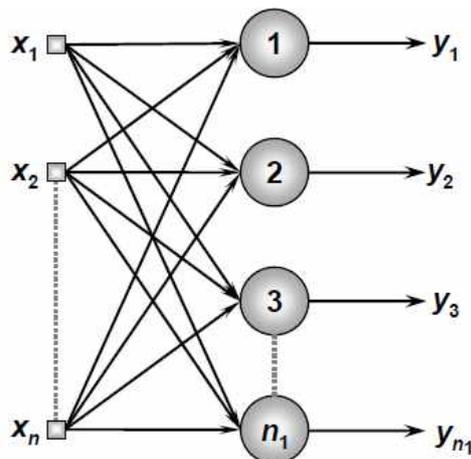
Uma vez que a rede é treinada e o erro atinge um nível aceitável, ela pode ser usada como procedimento para a classificar novos dados. Para esta finalidade, a rede só pode ser utilizada em modo progressivo (feedforward), isto é, novas entradas são exibidas a camada de entrada, são processadas nas camadas intermediárias e seus resultados são apresentados na camada de saída, como no treinamento, mas sem a retropropagação do erro [26].

3.10 Rede Learning Vector Quantization

A rede Quantização vetorial por Aprendizagem (LVQ), é um algoritmo que permite escolher quantidade instâncias de treinamento devem ser mantidas e aprende exatamente como essas instâncias devem ser. Devido à eficiência e facilidade de uso do método de implementação, é bastante reconhecido em problemas de classificação e reconhecimento de padrões [27].

A Figura 12, mostra uma rede LVQ composta de n entradas e n_1 neurônios, os quais estarão representadas todas as classes envolvidas em um problema de classificação de padrões.

Figura 12 – Ilustração topológica da LVQ.



Fonte Hornik, 1995.

O objetivo da aprendizagem, de modo do processamento de informações é ordenar no domínio das amostras analisadas, um conjunto de vetores de livros de códigos, onde são utilizados para a classificação de vetores que não são vistos. No começo, um conjunto de vetores aleatórios é formado e exposto a amostras de treinamento. Ao empregar uma estratégia, seleciona um ou mais vetores semelhantes a um determinado padrão de entrada, onde são ajustados para ficarem mais próximos do vetor de entrada ou, às vezes, mais distante do segundo colocado. Durante a repetição desse processo, o resultado é uma distribuição de vetores do livro de códigos no espaço de entrada que se aproxima da distribuição das amostras no conjunto de dados de teste. Esse algoritmo é utilizado para modelagem preditiva [27].

3.11 Considerações Finais

As redes neurais artificiais são frequentemente usadas para resolução de problemas complexos, onde o comportamento da variável não é estritamente conhecido. A principal característica é a capacidade de liderar pelo exemplo e generalizar informação aprendida, modelo generativo não linear, tornando útil na análise espacial muito eficiente.

Topologicamente, para implementar a RNA devem ser definidas variáveis diferentes, onde:

- a) O número de nós na camada de entrada.
- b) Número de camadas ocultas e os números de neurônios a serem colocados.
- c) O número de neurônios na camada de saída.

Diante do exposto, uma das características que fundamentam a aplicabilidade da rede neural é a capacidade de aprendizagem a partir de dados de entrada com ou sem a supervisão, fornecendo resultados satisfatórios, além de uma arquitetura adequada. Desta forma, faz necessário fornecer à rede dados representativos de flexibilidade de processo, em que a determinação desses valores deve ser realizada de tal forma em fornecer uma rede que dê bons resultados sem nenhum esforço de cálculo excessivamente.

Capítulo 4

4. MEDIDAS DE PRECIPITAÇÃO DA CHUVA

4.1 Introdução

Para avaliar os efeitos da chuva nos sistemas de comunicação, é importante conhecer a variabilidade local e os padrões temporais de chuva. À altura da água acumulada ao fim de uma hora de chuva constante chama-se taxa de precipitação e é medida em *mm/h*.

A atenuação por chuvas consiste na absorção e espalhamento da energia em propagação pelas partículas de água existente no meio. As gotas de chuvas comportam-se como um meio dielétrico dissipativo para o campo elétrico incidente, absorvendo energia ou espalhando em diversas direções. As dimensões das gotas tornam-se comparáveis ao comprimento de onda do sinal nas frequências acima de 10 GHz.

Neste capítulo é apresentada a precipitação da chuva como o principal requisito para a previsão da atenuação por chuva.

4.2 Medidas do INMET

Os dados foram coletados nas estações do Instituto Nacional de Meteorologia (INMET) [28], onde tem a missão de prover informações meteorológicas e influir construtivamente no processo de tomada de decisão. A partir de um documento “Normais Climatológicas” obtém dados climatológicos para várias cidades e optou-se por dez cidades de cada região.

4.3 Precipitação Anual da chuva

Como o aumento da gota da chuva é a principal fonte de atenuação de sinal ao longo do percurso, dados de chuva são utilizados para o cálculo da atenuação. A intensidade da precipitação é realizada por meio da taxa de queda da chuva R indicada por *mm/h*. A estatística

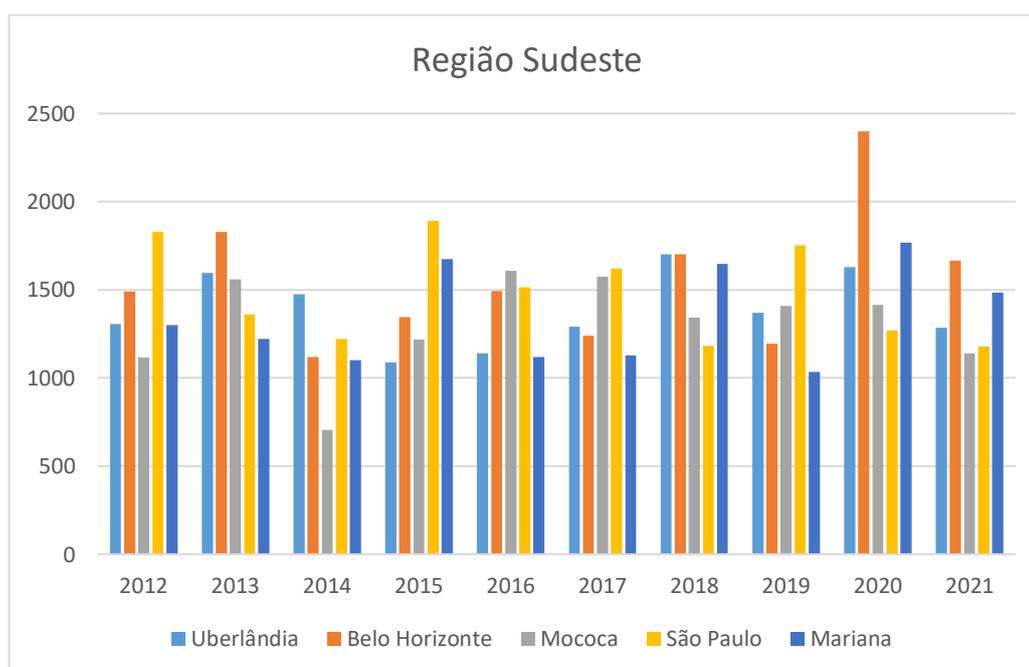
de precipitação temporal é atingida pela distribuição da probabilidade cumulativa, a qual sugere a porcentagem de tempo do ano p no decorrer de um dado valor da taxa de queda chuva $R_p(mm/h)$ seja excedido, ou seja, eventualmente o valor adotado é de $p = 0,01\%$, no qual equivale aproximadamente 53 minutos por ano. Os dados pluviométricos utilizados foram obtidos através do Instituto Nacional de Meteorologia (INMET) em diversas localidades no Brasil. As precipitações (mm/h) para as algumas cidades selecionadas são apresentadas conforme na Tabela 3 a 7.

Tabela 3 – Precipitação anual (mm) de algumas cidades selecionadas na região Sudeste.

	Ano									
Cidade	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Uberlândia	1307.4	1595.4	1474.8	1087.6	1140.8	1292.0	1702.0	1369.4	1627.8	1285.0
Belo Horizonte	1489.8	1827.4	1120.2	1343.8	1493.0	1239.2	1701.0	1193.0	2398.2	1664.4
Mococa	1115.2	1560.6	705.4	1217.4	1608.2	1576.0	1342.4	1409.0	1414.0	1139,6
São Paulo	1828.8	1359.6	1220.6	1890.6	1514.4	1619.6	1180.8	1752.2	1269.0	1179.6
Mariana	1301.2	1220.4	1100.4	1674.8	1118.9	1128.8	1647.4	1035.6	1766.6	1484.4

Fonte: INMET, 2012 - 2021.

Gráfico 3 – Precipitação anual região Sudeste.



Fonte: O autor.

Em Uberlândia as chuvas registradas durante em 10 anos variaram entre 1100 mm e 1710 mm. No Estado de Minas Gerais apresentou um comportamento um pouco semelhante em

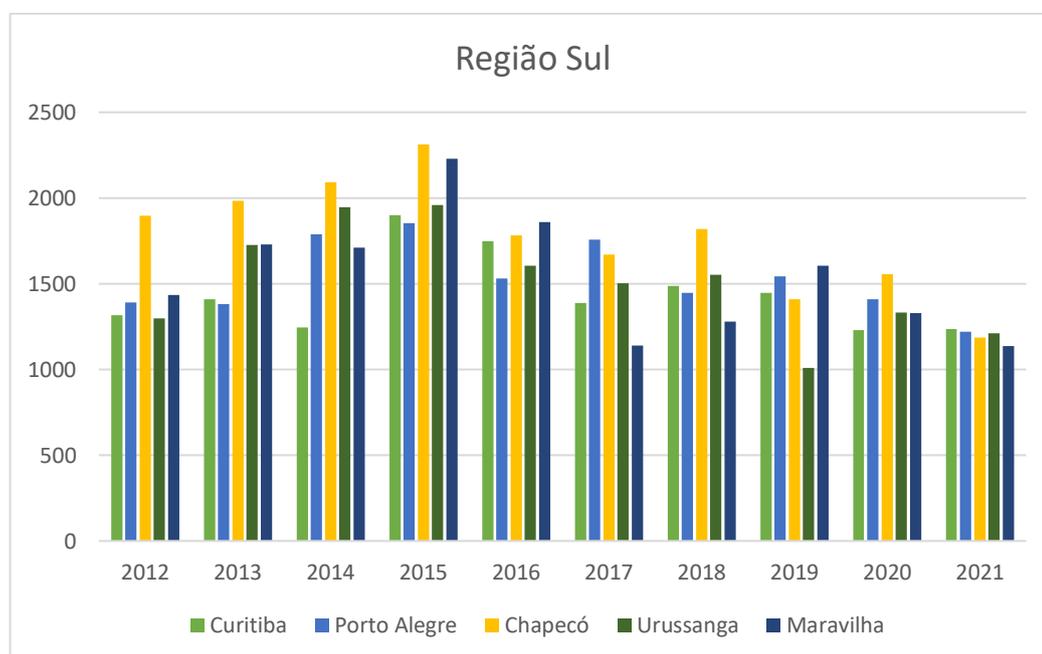
comparação no Estado de São Paulo. Em Mococa a anomalia negativa chegou em 705,4 mm no ano de 2014. Apesar disso, na região Sudeste obteve um índice de precipitação excelente, sendo assim apresentando resultados positivos.

Tabela 4 – Precipitação anual (mm) de algumas cidades selecionadas na região Sul.

	Ano									
Cidade	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Curitiba	1317.6	1409.9	1246.6	1900.4	1748.8	1387.0	1486.2	1447.6	1229.8	1235.4
Porto Alegre	1390.2	1381.2	1787.4	1853.2	1532.2	1756.6	1446.6	1542.8	1410.6	1221.0
Chapecó	1895.6	1985	2092.2	2313.4	1782.4	1670.0	1818.0	1409.4	1556.0	1187.6
Urussanga	1298.4	1725.2	1947.2	1959.6	1605.8	1502.4	1553.8	1008.9	1333.4	1209.6
Maravilha	1433.8	1728.0	1709.4	2228.8	1859.0	1138.2	1279.4	1605.8	1329.0	1135.0

Fonte: INMET, 2012 - 2021.

Gráfico 4 – Precipitação anual região Sul.



Fonte: O autor.

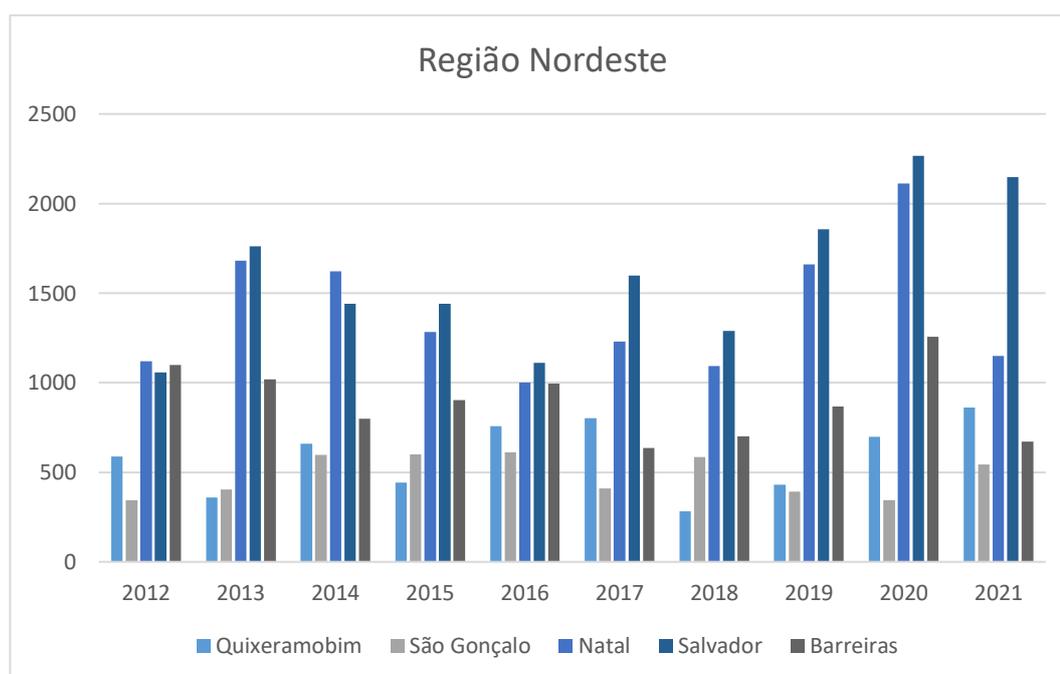
As precipitações maiores ocorreram em Chapecó e Maravilha, com valores 2313,4 mm e 2228,8 mm no ano de 2015. Os máximos índices de precipitação ocorrem no Estado de Santa Catarina, no qual caracteriza em resultados propício. No município de Maravilha que sucedeu a anomalia negativa em 2021 chegando no valor de 1135 mm, em comparação com outros Estados da região Sul.

Tabela 5 – Precipitação anual (mm) de algumas cidades selecionadas na região Nordeste.

	Ano									
Cidade	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Quixeramobim	587.6	358.8	659.3	442.4	756.8	801.6	281.0	431.2	697.2	860.4
São Gonçalo	345.8	404.2	596.4	600.2	612.2	408.8	585.6	392.6	344.0	544.6
Natal	1119.2	1682.0	1621.4	1284.4	999.4	1230.8	1093.6	1659.0	2112.8	1148.6
Salvador	1055.8	1759.8	1440.4	1441.8	1110.0	1597.2	1289.8	1855.4	2265.0	2147.4
Barreiras	1098.0	1017.2	798.8	903.3	996.2	635.2	702.2	867.4	1256.2	670.2

Fonte: INMET, 2012 - 2021.

Gráfico 5 – Precipitação anual região Nordeste.



Fonte: O autor.

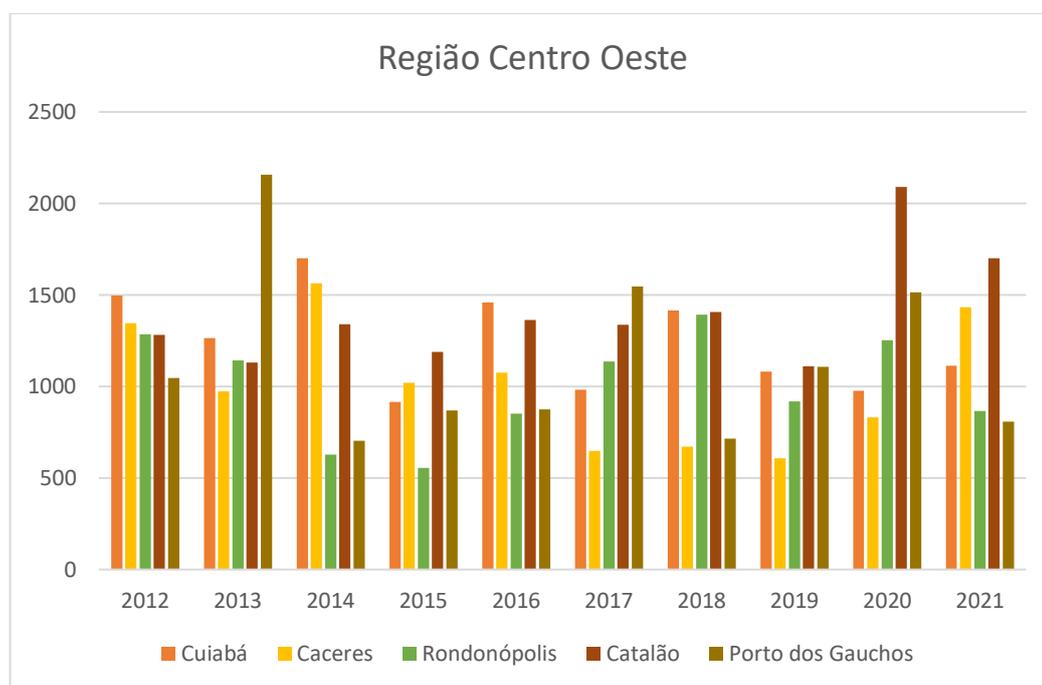
Os maiores valores de precipitação observados na região Nordeste ocorreram nos estados da Bahia e do Rio Grande do Norte e estiveram aproximadamente, entre 1000 e 2200 mm. Esses valores coincidiram com os maiores valores de anomalias positivas registradas. Na cidade de Salvador foi registrada essa anomalia positiva de 2265 mm no ano de 2020. Em Quixeramobim e São Gonçalo do Amarante apresentaram poucas chuvas, resultando em desvios negativos de precipitação.

Tabela 6 – Precipitação anual (mm) de algumas cidades selecionadas na região Centro-Oeste.

	Ano									
Cidade	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Cuiabá	1495.8	1264.2	1701.6	916.2	1460.2	983.6	1416.2	1081.8	976.2	1114.2
Cáceres	1346.8	973.6	1565.0	1021.4	1074.3	647.5	670.4	606.0	830.6	1433.0
Rondonópolis	1285.0	1142.0	627.6	555.6	852.4	1137.4	1391.6	917.2	1251.6	865,8
Catalão	1281.2	1131.0	1338.8	1188.8	1363.2	1337.6	1406.6	1109.8	2090.2	1700.4
Porto dos Gaúchos	1047.8	2157.0	703.0	869.2	874.2	1547.6	714.5	1106.6	1513.2	806.8

Fonte: INMET, 2012 - 2021.

Gráfico 6 – Precipitação anual região Centro Oeste.



Fonte: O autor.

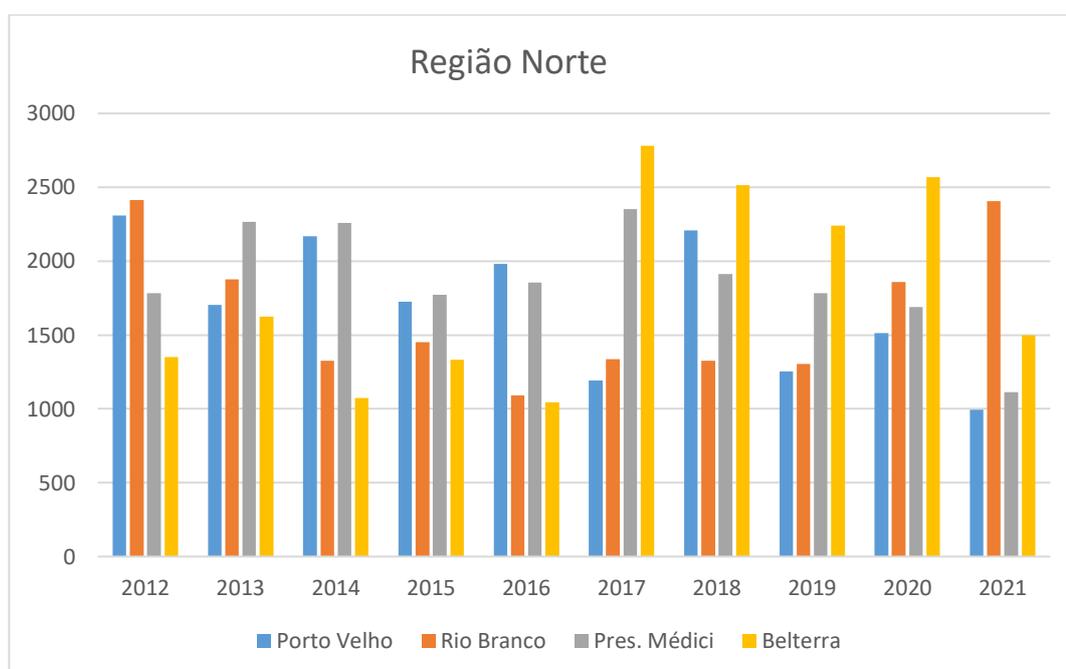
No ano de 2021, a precipitação variou entre 800 a 1700 mm em toda região Centro Oeste. Os maiores valores ficaram concentrados em Catalão no Estado de Goiás e Cuiabá no Estado de Mato Grosso. Nos campos de anomalias foram observadas grande déficit de chuva em Cáceres no Estado de Mato Grosso.

Tabela 7 – Precipitação anual (mm) de algumas cidades selecionadas na região Norte.

	Ano									
Cidade	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Porto Velho	2309.8	1703.6	2168.8	1724.8	1981.0	1191.2	2208.6	1252.4	1513.2	994.8
Rio Branco	2413.6	1878.0	1323.8	1451.0	1093.2	1334.6	1325.4	1305.4	1860.2	2406.2
Pres. Médici	1781.6	2265.4	2258.0	1772.0	1853.6	2352.2	1913.8	1784.6	1688.2	1112.4
Belterra	1350.0	1623.6	1073.8	1333.6	1046.2	2780.8	2516.2	2242.2	2570.0	1500.2

Fonte: INMET, 2012 - 2021.

Gráfico 7 – Precipitação anual região Norte.



Fonte: O autor.

Os maiores valores foram observados em Belterra município do estado do Pará, alcançando o valor de 2780.8 mm/h no ano de 2017. Foram observado uma anomalia negativa no ano 2021 na cidade de Porto Velho em Rondônia. Porém todas cidades analisadas, obtiveram resultados positivos em comparação outros estados Brasileiros.

4.4 Parâmetros geográficos

Alguns fatores que influenciam o clima podem ser oriundos da naturalidade ou até de interferência humana. A relação entre altitude, latitude, longitude e clima se manifesta não apenas em diferentes temperaturas dos tipos climáticos, mas também em condições como

precipitação, índice de vento e umidade. A seguir, entenderemos como cada um desses elementos afeta o comportamento da atmosfera.

4.4.1 Precipitação X Latitude

Em geral, as regiões próximas à linha do Equador recebem mais chuvas do que outras regiões, como os polos e regiões temperadas, isso se deve à maior incidência de raios solares nas regiões equatoriais proporcionando maior evaporação.

4.4.2 Precipitação X Altitude

À medida que uma massa de ar se aproxima de uma montanha, é forçada subir para temperaturas mais baixas, causando precipitação. Mas em determinadas alturas, quando a umidade do ar cai extremadamente o efeito é inverso e chove menos.

4.4.3 Precipitação X Longitude

A longitude não afeta diretamente o clima e a precipitação, mas o faz indiretamente, devido ao movimento das massas de ar para leste e oeste.

4.5 Parâmetros Geográficos

As estatísticas de precipitação para a área geográfica de um enlace podem estimar a probabilidade de exceder uma determinada taxa de precipitação para essa área e, portanto, a distribuição das probabilidades de atenuação da chuva. Os parâmetros geográficos de algumas cidades selecionadas no Brasil, em termos de Latitude, Longitude e Altitude (m), são apresentados na Tabela 6 a 10 [29].

Devido à sua localização geográfica, o clima do sudeste é basicamente tropical. Esta é uma área entre os trópicos, com altas temperaturas na maioria dos estados. No entanto, alguns fatores alteram seu clima, como altitude, nível do mar e latitude.

Tabela 8 – Parâmetros geográficos de algumas cidades selecionadas na região Sudeste.

Cidade	Latitude (graus)	Longitude (graus)	Altitude (metros)
Uberlândia	-18.9113	-48.2622	843
Belo Horizonte	-19.8157	-43.9542	767
Mococa	-21.4708	-47.0006	549
São Paulo	-23.5489	-46.6388	745
Mariana	-20.3780	-43.4167	712

Fonte: Geografos, 2020.

Na região sul é praticamente subtropical apresentando as quatro estações do ano bem definidas, com verões quentes, invernos rigorosos e chuvas bem distribuídas ao longo do ano.

Tabela 9 – Parâmetros geográficos de algumas cidades selecionadas na região Sul.

Cidade	Latitude (graus)	Longitude (graus)	Altitude (metros)
Curitiba	-25.4284	-49.2753	925
Porto Alegre	-30.0277	-51.2287	22
Chapecó	-27.0968	-52.6186	659
Urussanga	-28.5227	-49.3176	25
Maravilha	-26.7606	-53.1748	572

Fonte: Geografos, 2020.

A região Nordeste em uma área de baixa latitude, sofre poucas variações ao longo do ano, durante o dia quanto á noite, causando secas severas em alguns estados e abundância de chuva em outros.

Tabela 10 – Parâmetros geográficos de algumas cidades selecionadas na região Nordeste

Cidade	Latitude (graus)	Longitude (graus)	Altitude (metros)
Quixeramobim	-5.19812	-39.2962	199
São Gonçalo do Amarante	-3.60733	-38.9705	18
Natal	-5.79448	-35.211	38
Salvador	-12.9704	-38.5124	12
Barreiras	-12.1482	-44.9925	454

Fonte: Geografos, 2020.

O clima na região Centro oeste possui duas estações bem definidas, uma seca e uma chuvosa, e as temperaturas são bastante altas.

Tabela 11 – Parâmetros geográficos de algumas cidades selecionadas na região Centro-Oeste.

Cidade	Latitude (graus)	Longitude (graus)	Altitude (metros)
Cuiabá	-15.5989	-56.0949	180
Cáceres	-16.0669	-57.6868	126
Rondonópolis	-16.4713	-54.6371	222
Catalão	-18.1721	-47.9415	858
Porto dos Gaúchos	-11.5252	-57.4138	246

Fonte: Geografos, 2020.

Na região Norte apresentam temperaturas elevadas, alto índice pluviométrico, elevada umidade e ventos leves.

Tabela 12 – Parâmetros geográficos de algumas cidades selecionadas na região Norte.

Cidade	Latitude (graus)	Longitude (graus)	Altitude (metros)
Porto Velho	-8.76183	-63.902	83
Rio Branco	-9.974	-67.8076	143
Pres. Médici	-11.1718	-61.9032	191
Belterra	-2.69829	-54.8883	146

Fonte: Geografos, 2020.

4.6 Considerações Finais

A variação na taxa de chuva observado em localidades diferentes, demonstrou baixa taxa pluviométrica anual, podendo apresentar altas intensidades de chuvas ao longo dos anos. Essas variações podem ser interferidas pelo relevo e a temperatura em regiões no Brasil.

Os dados obtidos através do banco de dados são bastante utilizados nas telecomunicações quando se pretende o tratamento de dados de chuvas extremas em diversas localidades do Brasil. Conforme visto neste capítulo, os dados de precipitações de chuvas e dados geográficos servirá de grande suporte para a implementação das atenuações utilizando redes neurais.

Capítulo 5

5. REDES NEURAIS PARA PREVISÃO DA ATENUAÇÃO

5.1 Introdução

Neste capítulo são exibidos os resultados obtidos pelas aplicações das redes neurais especificamente da rede MLP e rede LVQ apresentados no capítulo 3 à solução utilizando essas redes para a previsão da atenuação. São exibidos os resultados obtidos em comparação com o modelo ITU apresentados no Capítulo 2.

5.2 Procedimento para a criação da RNA

Os procedimentos para a criação de RNAs baseiam se nas referências [30,31,32,33] e são essencialmente os seguintes:

- a) Partição da base de dados;
- b) Parametrização da criação das redes;
- c) Investigação de um sequencial do número de neurônios na camada oculta;
- d) Uso de método de validação para determinação da melhor rede.

O software utilizado pela criação das redes neurais MATLAB (MaTriX LABoraty) trata se de um software interativo de alta performace voltado para cálculo numérico.

5.2.1 Partição da base de dados

As redes neurais aprendem com exemplos e são projetadas para serem capazes de generalizar o conhecimento adquirido durante as sessões de treinamento. A divisão do banco de dados é uma estratégia eficaz para generalizar as redes neurais que tem um impacto significativo em seu desempenho. Este procedimento consiste em criar uma matriz com os pontos de entrada e saída desejados na mesma linha, bem como uma permutação aleatórias das linhas, e depois dividir em três conjuntos diferentes, onde 60% dos parâmetros são usados para

criar o conjunto de treinamento, 30% para criar o conjunto de validação e 10% para criar o conjunto de teste.

Nossa base de dados inicializa em 01 janeiro de 2012 e finaliza no dia 31 de dezembro de 2021, escolheu se salvar os anos de 2020 e 2021 para avaliação das RNAs em simulação em tempo real do seu uso, resultando em menos dados para aprendizagem.

5.2.2 Parametrização da criação das redes

As redes neurais artificiais com a arquitetura Multi Layer Perceptron (MLP) aprendem durante o processo de treinamento atualizando os pesos. O algoritmo de retropropagação de erros é baseado no princípio da correção de erros, que é a diferença entre o valor obtido pela rede e o valor desejado. Utilizando o método do gradiente descendente, este algoritmo busca minimizar o erro. A atualizações dos pesos é uma constante derivada do erro e por uma constante denominada taxa de aprendizagem, podendo ser levado a uma convergência vagarosa do método ou mesmo a não convergência.

A arquitetura da LVQ consiste em atribuir um único vetor a cada uma dessas classes, conhecidos como quantizador. Nesse caso o quantizador representa o perfil que cada grupo possui em relação as novas operações de classificação amostral. Como resultado, uma nova amostra será classificada como pertencente à classe específica, o objetivo da quantização vetorial seria obter um quantizador que estaria estacionado em um local estratégico cuja a distância de todos os exemplares da classe seria igual à soma de suas distâncias.

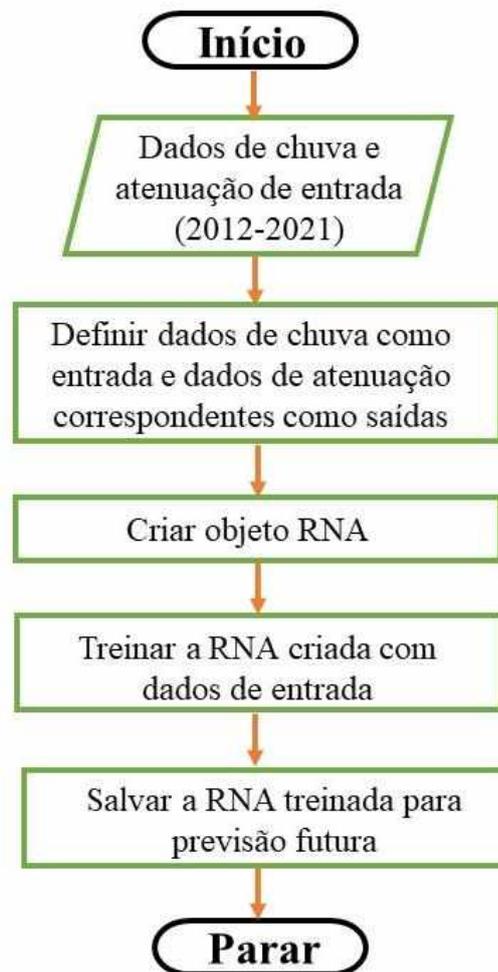
Todos os experimentos realizados neste trabalho criaram RNAs com a arquitetura MLP e LVQ, conforme mostra no decorrer desta dissertação. Os nodos das camadas escondidas possuem a função de ativação tangente hiperbólica e os nodos da camada de saída possuem a função de ativação sigmoide.

Durante a fase inicial do treinamento, o número de erros no conjunto de validação geralmente diminui. No entanto, quando a rede começa a memorizar dados de treinamento, o número de erros no conjunto de validação aumenta. Quando um erro no conjunto de validação aumenta em um número específico de iterações, o treinamento parado e os pesos e bias são retornados para os valores do erro mínimo de validação.

Essa dissertação utiliza RNA para prever a atenuação da chuva de locais quando a taxa de chuva é fornecida ao objeto da RNA como entrada. Assim, em vez de calcular a atenuação

da chuva utilizando o algoritmo ITU, o intuito é utilizar redes neurais diretamente. A Figura 13, mostra um fluxograma de como é realizado o processo de treinamento da RNA.

Figura 13 – Processos de treinamento da RNA para previsão da atenuação de chuva.



Fonte: O autor.

O objeto da RNA é criado usando um algoritmo aprendido da rede neural feedforward backpropagation, com outros parâmetros da rede. Após a criação do objeto RNA, ele é treinado com os dados de entrada que são os dados de taxa de chuva coletados do INMET. A RNA continua aprendendo a correlação dos dados de chuva com os valores de atenuação correspondentes até que a meta de desempenho seja atingida.

O objetivo de desempenho é interromper o treinamento assim que atingir o resultado mais próximo possível do esperado. O objeto treinado da RNA é salvo para o uso futuro para

prever a atenuação da chuva para um dado local geográfico. Os dados pluviométricos 2012 a 2021 foram usados para treinar a rede.

5.2.3 Investigação de um sequencial do número de neurônios na camada oculta

Durante esta fase, o número de nós na camada oculta varia. O número de nodos escolhidos é determinado pelo MSE da mediana mais baixa do conjunto de validação. É importante salientar que quando uma das redes apresenta um alto nível de complexidade causado por um grande número de entradas, um grande número de nodos em uma camada oculta, ou mesmo ambas as causas, a rede tende a ser mais influenciados pela inicialização dos pesos, o que pode fazer com que convergirem imaturo. Os resultados dessas redes são contabilizados no cálculo MSE do conjunto de validação nesses casos. A mediana foi utilizada para organizar as redes e, por fim, para escolher a melhor opção.

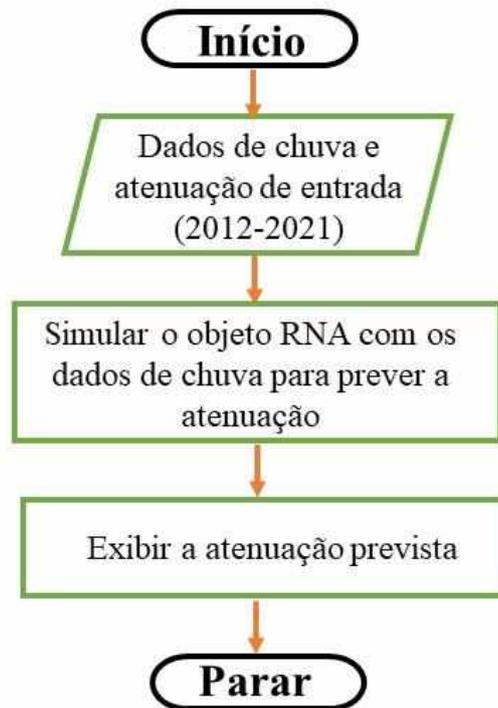
5.2.4 Uso de método de validação para determinação da melhor rede.

O próximo passo após decidir sobre as melhores arquiteturas para cada uma das opções de busca foi encontrar a melhor rede para cada um dos sistemas de previsão. Em seguida, iniciou-se a busca pela melhor rede, empregando a técnica de validação com auxílio à busca. Essa técnica é normalmente usada para calcular a verdadeira taxa de erro, de acordo com especialista.

5.3 Procedimentos para Teste Criado

Após o objeto RNA ter sido devidamente treinado, ele pode ser usado para prever a atenuação da chuva para os locais específicos para os quais foi treinado. Para prever a atenuação da chuva de qualquer localidade, os dados de chuva do local são carregados na rede neural, conforme mostrado no processo representado pelo fluxograma Figura 14. Os dados são simulados com o objeto RNA, consequentemente a RNA produz os dados de atenuação para cada valor de precipitação previsto.

Figura 14 – Processos de treinamento da RNA para previsão da atenuação de chuva.



Fonte: O autor.

Para testar a capacidade do objeto da RNA treinado em prever adequadamente a atenuação da chuva quando a taxa de chuva é fornecida a ele, os dados de chuva de 2019 a 2020 que não faziam parte daqueles usados para treinar a RNA. O teste foi realizado para os três anos separadamente para prever a atenuação da chuva para cada um dos anos.

5.4 Desempenho da previsão da RNA nas atenuações da chuva

Os resultados demonstram que a RNA oferece um desempenho de previsão muito bom em comparação com o modelo ITU, apesar de alguns resultados não terem atingido o valor esperado. Assim, a RNA pode ser utilizada no lugar dos cálculos realizados pelo modelo ITU. Além disso, a RNA pode ajudar a prever um número muito grande de locais ao mesmo tempo com pouco ou sem complexidade computacional, em comparação com o algoritmo ITU que exige que cada local seja calculado separadamente, o que consumia muito tempo e era mais complexo para de manusear.

5.4.1 Modelo MLP

A primeira rede utilizada foi a MLP, onde o algoritmo consistia em prever a atenuação, e posteriormente fazer comparação com o modelo ITU-R. As camadas intermediárias (ocultas) tem o propósito de representar diversas nuances que os dados de treinamento podem ter. Para isso, aplicou três camadas ocultas, para o melhor ajuste da rede. A função de ativação utilizada foi a sigmoide por ser usada com propagação positiva (Feedforward) que precisam ter como saída apenas números positivos, e por ser uma função crescente, que mostra um balanço entre o comportamento linear e não linear. A MLP apresentou os seguintes resultados conforme mostrado na Tabela 13.

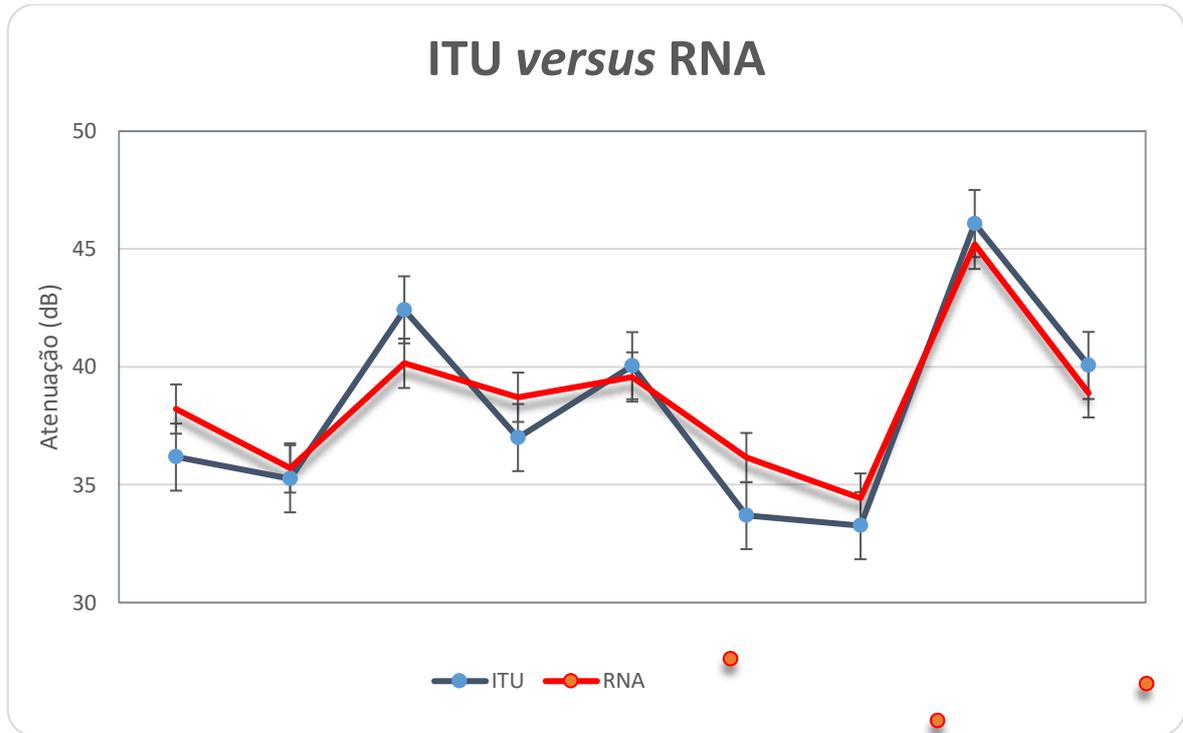
Tabela 13 – Resultados da MLP.

Cidade	ITU-R (dB)	MLP (dB)
Bauru	36.17	38.21
Bragança Paulista	35.25	35.71
Campo Grande	42.42	40.15
Coronel Pacheco	37.0	38.71
Dourados	40.05	39.57
Eldorado	33.69	36.15
Porto Alegre	33.26	34.43
Rio Branco	46.08	45.20
Salvador	40.06	38.90

Fonte: O autor.

Podemos observar alguns resultados obtidos pela rede MLP estão próximos dos cálculos recomendados pela ITU-R. Na cidade de Bragança Paulista, Dourados e Rio Branco apresentaram as melhores aproximações com as seguintes diferenças respectivamente 0.46 dB, 0.48 dB e 0,88 dB, ou seja, menor que 1 dB. Já na cidade de Eldorado atingiu o maior índice de erro de 2.46 dB de diferença.

Figura 15 – Comparação ITU versus RNA.



Fonte: O autor.

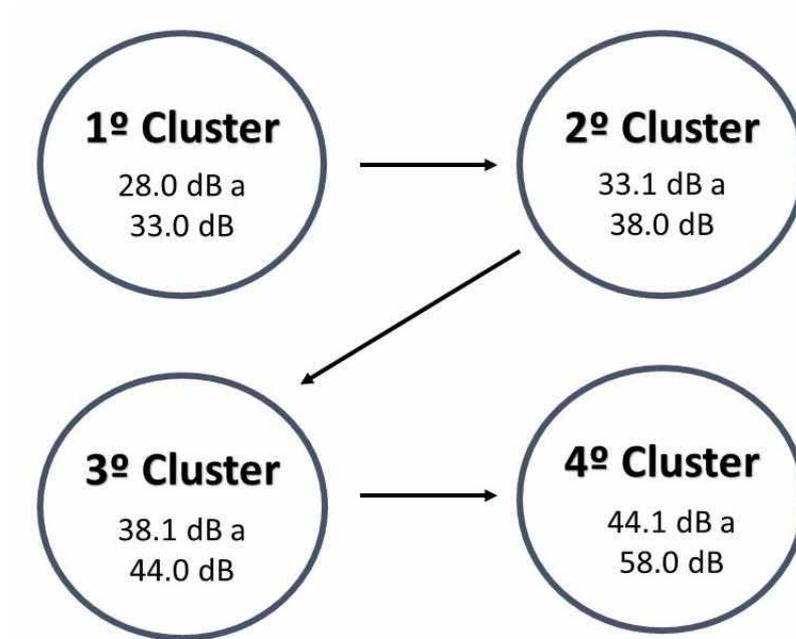
Os resultados da rede são apresentados na Figura 15. Nessa figura compara a saída obtida usando cálculos complexos proposto pela ITU e o algoritmo MLP para as saídas da rede. Em geral, os resultados previstos pela rede RNA (linha vermelha) são muito mais densos em seguir padrões de dados reais ou observações (linha azul) conforme o modelo ITU.

Para avaliar a quantitativamente o desempenho do modelo, calculamos a correlação entre a atenuação do modelo ITU e as saídas utilizando o algoritmo da RNA com vários parâmetros durante o processo de treinamento. Podemos observar claramente que o modelo MLP é bastante aceitável para a previsão da atenuação provocada pela chuva.

5.4.2 Modelo LVQ

Em seguida, foi aplicada a rede LVQ, onde se dividiu em quatro clusters, com o objetivo de colocar uma determinada cidade no teste da rede, classificando a faixa de atenuação pertencente. A separação da faixa de atenuação foi adotada da seguinte forma como:

Figura 16 – Divisão de cluster para arquitetura LVQ.



Fonte: O autor.

Por utilizar aprendizado supervisionado a rede recebeu um conjunto de padrões de treinamento com classificação conhecida junto com uma distribuição inicial da classe de saída. Utilizamos algumas cidades para o devido teste, onde os resultados obtidos pela LVQ estão apresentados na Tabela 14.

Tabela 14 – Resultados da LVQ.

CIDADE	ATENUAÇÃO (dB)	CLUSTER
Bauru	36.17	2º
Campo Grande	42.42	3º
Coronel Pacheco	37.0	2º
Eldorado	33.69	2º
Porto Velho	33.26	0
Salvador	46.08	3º
Uberlândia	40.06	1º

Fonte: O autor.

A rede LVQ demonstrou 85,71% dos acertos, conforme demonstrado acima. Apresentou se erro apenas em Porto Velho, no estado em Rondônia, pois os dados obtidos através de medições apresentaram valores acima do esperado. Com isto, o resultado obtido foi nulo devido ao conjunto de dados utilizado na rede neural terem os valores abaixo de 51.70 dB.

Devido aos valores obtidos a rede neural LVQ apontou resultados aceitáveis para prever a faixa de atenuação da chuva em diversas localidades geográficas.

5.4.3 Comparação modelo MLP com a LVQ

Nesse estudo, dois métodos de algoritmos RNA, o MLP e o LVQ, foram usados para a previsão da atenuação devido à chuva. A análise estatística foi realizada para avaliar a precisão da predição de cada algoritmo. Verifica se que o algoritmo LVQ apresenta melhores resultados comparados ao algoritmo MLP para processos de aprendizado e teste.

A relação existente entre as atenuações observadas e estimadas na rede MLP mostrou um coeficiente de correlação linear $r = 0,67$ indicando uma correlação moderada, enquanto na rede LVQ verificou se uma forte correlação, com coeficiente linear de $r = 0,81$. Para minimizar erros, ambas arquiteturas devem ter uma longa camada oculta com um grande número de neurônios e uma enorme quantidade de dados de medições. No entanto, leva muito tempo para encontrar o melhor desempenho. Isso tem um impacto na duração relativamente curta do tempo de iteração. Portanto, a precisão da determinação da arquitetura também afeta o desempenho da duração do tempo de iteração.

Isso mostra que as RNA apresentaram resultados satisfatórios e conseguiram descrever as variações das atenuações estudado. Através desses resultados é possível prever faixa para taxa de chuva que são excedidas em 0,01 % (conforme o ITU propõe) por região do Brasil, conforme a Tabela 15.

Tabela 15 – Faixas para as taxas de chuva que são excedidas em 0,01% por região do Brasil.

Região do Brasil	Faixa para $R_{0,01\%}$
Norte	50 – 80 mm/h
Nordeste	30 – 60 mm/h
Centro Oeste	40 - 60 mm/h
Sudeste	40 - 70 mm/h
Sul	50 - 70 mm/h

Fonte: O autor.

Após sabermos a taxa de chuva em cada região do Brasil, foi gerada a Tabela 16, para previsão da atenuação provocada pela chuva, com taxa de chuva excedida de 0,01 % (conforme o ITU propõe) por região do Brasil.

Tabela 16 - Faixas para as atenuações por região do Brasil.

Região do Brasil	Atenuação
Norte	40 – 60 dB
Nordeste	20 – 40 dB
Centro Oeste	20 – 45 dB
Sudeste	25 - 50 dB
Sul	30 – 55 dB

Fonte: O autor.

A precisão da atenuação devido à chuva é muito importante devido á atual mudança climática mundial. A previsão das chuvas desempenha um papel significativo e a previsão necessita diminuir substancialmente o custo de impacto referente a questões relacionadas às chuvas. Portanto, este estudo se concentra nas capacidades da rede neural usando técnicas diferentes de treinamento de fenômenos climáticos que interferem em sinais, como a chuva. Pode se dizer que ambos as arquiteturas podem servir para calcular se a atenuação, já que os valores dos seus erros apresentaram valores não tão relevantes devido ao banco de dados utilizados. Os resultados também mostraram que devido ao alto desenvolvimento anualmente das regiões, como por exemplo mudança climáticas, pode sim interferir no sinal nas comunicações.

5.5 Considerações Finais

O aprimoramento futuro deste projeto pode ser uma abordagem sobre como reduzir a porcentagem de erros presentes, para que ajude a melhorar o nível de previsão dentro do tempo e complexidade disponíveis. A precisão dos algoritmos pode ser testada adicionalmente em aumento da complexidade. Muitos outros tipos de erros podem ser calculados para testar a

precisão dos algoritmos acima. Testes diários como o aumento do conjunto de dados base em vez do conjunto de dados acumulados pode ser de importância primordial para novas pesquisas.

Assim, a metodologia proposta atualmente funciona bem para a predição da atenuação provocada pelas chuvas, o mesmo pode ser utilizado com interferências como é o caso da temperatura, umidade, gases e etc.

Capítulo 6

6. CONCLUSÕES FINAIS

6.1 Introdução

Destaca-se os aspectos da pesquisa e conclusões do trabalho apresentado nesta dissertação neste capítulo. Além disso, algumas sugestões para trabalhos futuros e contribuições científicas para o trabalho atual serão apresentados.

6.2 Análise Final

O presente estudo propõe uma metodologia para determinar parâmetros ideais para arquiteturas de rede neural supervisionadas como resultado para determinar a atenuação causada pelas chuvas nas comunicações. A dificuldade de definir uma boa arquitetura é colocada uma questão de otimização. Duas estratégias diferentes foram utilizadas ao mesmo tempo: a perceptron multicamadas e a quantização vectorial de aprendizagem.

O tema sugerido neste trabalho é considerado relevante. Redes neurais são um tipo de inteligência artificial que tem demonstrado sua eficácia em diversos campos. A meteorologia e a atenuação é um desses campos que as redes neurais estão ganhando terreno, cada vez mais aplicabilidade. Embora haja uma leve tendência a suavizar essas variações, as redes neurais são capazes de descrever variações de precipitação ao longo do período estudado.

Modelos de previsão baseados em redes neurais são simples de implementar, e não requer o uso de computadores poderosos. Desta forma, trata-se de uma metodologia podendo ser usada para previsão das atenuações em centros regionais e mesmo grandes sistemas operacionais.

As redes neurais MLP e LVQ foram aplicadas como modelo alternativo na aplicação de previsão da atenuação provocada devido à chuva, ou seja, uma técnica não convencional para assimilação de dados e modelo diferente proposto pela Recomendação da ITU.

A primeira aplicação consiste em utilizar a MLP para prever atenuação em algumas localidades no território Brasileiro. A partir dos resultados, verifica-se que as redes que tiveram

valores aproximados do esperado utilizando o modelo matemático proposto pela ITU. O resultado obtido apresentou uma boa aproximação, com uma faixa de erro de 0.45 dB à 3.0 dB – ver Tabela 13 em subseção 5.4.1. Uma vez treinada a rede neural o esforço computacional é menor, o que torna a rede neural mais apta para lidar com grande volume de dados.

O segundo estudo proposto neste trabalho foi o desenvolvimento de um modelo para regiões Sul, Sudeste, Norte, Nordeste e Centro Oeste, a partir de dados pluviométricos do banco de dados da INMET. A rede LVQ foi dividido em clusters com o objetivo de classificação da faixa de atenuação pertencentes. Por ser utilizado a aprendizagem supervisionado, a rede recebe um conjunto de padrões de treinamento com classificação conhecida junto com uma distribuição de saída. O resultado demonstrou 85% acertos, ou seja, apresentou resultados satisfatórios aceitáveis para prever a faixa de atenuação da chuva em certas regiões geográficas – ver Tabela 14 em subseção 5.4.2. Além disso, é uma alternativa para lidar com grandes volumes de dados, uma característica típica da meteorologia.

Por fim conclui se que, embora a abordagem de redes neurais tenha sido aplicada em duas redes neurais distintas para previsão da atenuação, é uma metodologia genérica e mostra se robusta o suficiente para ser adaptado e aplicado a qualquer problema que possa ser resolvido usando redes neurais. Uma das maiores vantagens do uso das redes e podem ser implementadas sem cálculos matemáticos muito complexos, além de trabalhar com dados medidos localmente nas regiões com alteração climáticas ao longo dos anos.

6.3 Previsões Futuros

Para o desenvolvimento futuro, nesta seção são propostos alguns trabalhos como os apresentados abaixo:

- Busca por melhorias dos métodos para previsão da atenuação sem a utilização de cálculos complexos;
- Utilizar de banco de dados maiores detalhadas para previsão da atenuação de acordo com a cidade;
- Desenvolvimento de um software para quando o usuário digitar parâmetros de uma certa região, ter como saída a atenuação para facilitar a implementação das comunicações;

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] IPPOLITO, L.J. **Satellite Communications Systems Engineering: Atmospheric Effects, Satellite Link Design and System Performance**. First. Washington, DC: Wiley, 2008. ISBN 978-0-470-72527-6. <https://doi.org/10.1002/9780470754443>
- [2] ALLNUT, JEREMY. **Space to earth radio propagation**. New York: John Wiley & Sons, 1992.
- [3] PÉREZ GARCÍA, Nelson Alexander. **Modelamento de Efeitos de Atenuação por Chuvas em Enlaces Terrestres Ponto-a-ponto e Ponto-multiponto**. Orientador: Luiz Alencar Reis da Silva Mello. 2003. Tese doutorado (Engenharia Elétrica) - PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO, Rio de Janeiro, 2003
- [4] SILVA MELLO, L. A. **Atenuação por Chuvas**. Notas de Aula do Curso de Propagação Troposférica. Pós-Graduação, Período 98.1, CETUC-PUC/Rio. 1998. Rio de Janeiro.
- [5] PEREZ GARCÍA., N. A. **Cálculo de Cobertura de Sistemas WLL e LMDS**. Rio de Janeiro, Abril 2000. p. 223. Dissertação de mestrado - Pontifícia Universidade Católica do Rio de Janeiro.
- [6] RECOMMENDATION ITU-R P. 618-12. **Propagation data and prediction methods required for the design of Earth space Telecommunication system**, 2013.
- [7] COSTA, Guilherme. **Uso de redes neurais na correção de erros de transmissão em sistemas de comunicação via satélite**. Orientador: Marco Antonio Brasil Terada. 2009. Tese dissertação (Engenharia Elétrica) - Universidade Federal de Brasília, [S. l.], 2009.
- [8] ALENCAR DE ARRUDA, Benedito. **Estudo comparativo das técnicas para cálculo de atenuação devido á chuva**. Orientador: Gilberto Arantes Carrijo. 2008. Dissertação (Mestrado Engenharia Elétrica) - Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, [S. l.], 2008. Disponível em: <https://repositorio.ufu.br/handle/123456789/14396>. Acesso em: 1 de outubro de 2019.

- [9] KOVÁCS, Zsolt László. **Redes neurais artificiais**. Editora Livraria da Física, 2002.
- [10] SPÖRL, C.; CASTRO, E. G.; LUCHIARI, A. **Aplicação de Redes Neurais Artificiais na construção de modelos de fragilidade ambiental**. Revista do Departamento de Geografia, v. 21, n.1, p. 113-135, 2011. <https://doi.org/10.7154/RDG.2011.0021.0006>
- [11] W. S. McCulloch and W. Pitts. **A logical calculus of the ideas immanent in nervous activity**. The bulletin of mathematical biophysics, 5(4):115–133, 1943. <https://doi.org/10.1007/BF02478259>
- [12] The organization of behavior: **A neuropsychological theory**. D. O. Hebb. John Wiley And Sons, Inc., New York, 1949.
- [13] B. Widrow et al. **Adaptive "Adaline" neuron using chemical "memistors"**. Number Technical Report 1553-2. Stanford Electron. Labs., Stanford, CA, October 1960.
- [14] Minsky, M. (1952). **A neural-analogue calculator based upon a probability model of reinforcement**. Harvard University Psychological Laboratories internal report.
- [15] Perceptrons. **An Introduction to Computational Geometry**. MARVIN MINSKY and SEYMOUR PAPERT. M.I.T. Press, Cambridge, Mass, 1969.
- [16] TATIBANA, Cassia Yuri; KAETSU, Deisi Yuki. **Redes Neurais**. Disponível em: Acesso em: 30 julho 2020.
- [17] Fausett, L., **Fundamentals of Neural Networks: Architectures, Algorithms, and Applications**, Dorling Kindersley India, 2004.
- [18] HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. Ed. Tradução de Paulo Martins Engel. São Paulo: Editora Artmed LTDA, 1999.
- [19] Silva, Ivan N.; Spatti, Danilo H.; Flauzino, Rogério A; **Redes Neurais Artificiais para engenharia e ciências aplicadas**, Artliber, 2010.

- [20] M. H. Hassoun, **Fundamentals of Artificial Neural Networks**, MIT Press, Massachusetts, 1995.
- [21] JAIN, A. K, MAO, J., MOHIUDDIN, K.M. **Artificial neural networks: a tutorial**. IEEE Computer, v. 29, n. 3, p. 56-63, 1996. <https://doi.org/10.1109/2.485893>
- [22] Chauvin, Y., Rumelhart, D.E., **Backpropagation: Theory, Architectures, and Applications**, Lawrence Erlbaum Associates, 1995.
- [23] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. **Learning representations of back-propagation errors**. Nature (London), vol. 323, pp. 533–536, 1986. <https://doi.org/10.1038/323533a0>
- [24] Silva, I. N. (2010). **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático**. Artliber Editora.
- [25] Chauvin, Y., Rumelhart, D.E., **Backpropagation: Theory, Architectures, and Applications**, Lawrence Erlbaum Associates, 1995.
- [26] HORNIK, K., STINCHCOMBE, M., WHITE, H. **Universal approximation of an unknown function and its derivatives using multilayer feedforward networks**. Neural Networks, vol. 3, no. 5, pp. 551-560, 1990. [https://doi.org/10.1016/0893-6080\(90\)90005-6](https://doi.org/10.1016/0893-6080(90)90005-6)
- [27] C.M.Bishop (1995). **Neural Networks for Pattern Recognition**, Clarendon Press. <https://doi.org/10.1201/9781420050646.ptb6>
- [28] INSTITUTO Nacional de Meteorologia. [S. l.], 1 maio 2020. Disponível em: <https://portal.inmet.gov.br>. Acesso em: 2 maio 2020.
- [29] Geografos, coordenadas. [S. l.], 1 jan. 2020. Disponível em: www.geogrados.com.br/cidades. Acesso em: 2 maio 2020.

[30] AQUINO, R. R. B., FERREIRA, A. A.; LIRA, M. M. S.; et al. **Previsão de Carga Horária em Médio Prazo Utilizando Redes Neurais com Foco na Previsão dos Feriados.** In: VII Congresso Brasileiro de Redes Neurais – VII CBRN, Natal -RN. P. 1-6, outubro 2005.

[31] AQUINO, R. R. B., FERREIRA, A. A.; NÓBREGA NETO, O.; et al. . **Previsão de Carga Horária em Médio Prazo Utilizando Redes Neurais Artificiais, Modelos para o Sistema da CELPE.** In: 25th Iberian Latin American Congress on Computational Methods – XXV CILAMCE. CIL32, p. 1-6. Recife – PE, 2004.

[32] AQUINO, R. R. B., FERREIRA, A. A.; NÓBREGA NETO, O.; et al. . **Previsão de Carga em Curto e Médio Prazo Utilizando Redes Neurais Artificiais: Uma Aplicação ao Sistema CELPE.** In: XVI Seminário Nacional de distribuição de Energia Elétrica – XVI SENDI. No.330, p.1-6. Brasília -DF, 2004.

[33] AQUINO, R. R. B., FERREIRA, A. A.; LIRA, M. M. S.; et al. **Sistema Inteligente Híbrido de Previsão de Carga em Curto e Médio Prazo Aplicado ao Sistema CELPE.** In: X Symposium of Specialists in Electric Operational – SEPOPE, Florianopolis – SC, 2006.