

UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
ENGENHARIA DE TELEINFORMÁTICA

**PREDIÇÃO DO SINAL EM UMA REDE LOCAL SEM FIO ATRAVÉS
DE REDES NEURAS ARTIFICIAIS**

RICARDO BRUNO MARTINS TEIXEIRA

FORTALEZA – CE

2009

RICARDO BRUNO MARTINS TEIXEIRA

**PREDIÇÃO DO SINAL EM UMA REDE LOCAL SEM FIO ATRAVÉS
DE REDES NEURAIS ARTIFICIAIS**

Monografia submetida à
Coordenação da Engenharia
de Teleinformática da
Universidade Federal do Ceará
como requisito para obtenção
da graduação em Engenharia
de Teleinformática.

Orientador: Prof. Dr. Francisco Rodrigo Porto Cavalcanti

Fortaleza – CE

2009

*Aos meus pais, Vicente e Jaci, ao meu irmão Rodrigo
e à minha namorada Bruna, pelo amor incondicional.*

AGRADECIMENTOS

Ao professor Rodrigo pela orientação, apoio e pelas preciosas observações, que incentivaram num aprofundamento das pesquisas e na busca pelos melhores resultados possíveis.

Aos amigos da faculdade, sempre prestativos e que apoiaram nos momentos de maior insegurança.

À minha família, sem a qual nunca teria realizado o sonho de me tornar engenheiro e que, mais do que ninguém, merece essa conquista.

À minha namorada Bruna, a qual foi compreensível e carinhosa em todo o período estressante do trabalho, permanecendo ao meu lado em qualquer situação.

RESUMO

O foco do presente trabalho foi a busca de um modelo de propagação do sinal em redes *wireless indoor*. A formulação de modelos para este tipo de sistema, devido a diversas particularidades existentes (como *layout* do ambiente entre a antena transmissora e a receptora, a quantidade de obstáculos, o material do qual é feito os obstáculos, etc.), permanece sendo um problema de difícil solução, apesar da grande diversidade de estudos já realizados sobre o assunto.

Foram desenvolvidos modelos de propagação através de redes neurais artificiais, comparando os resultados obtidos pelos mesmos com os resultados de alguns dos modelos semi-empíricos existentes na literatura. Neste sentido, buscava-se um modelo que melhor se adequasse as características do ambiente alvo, capaz de prever valores em outros pontos do mesmo ambiente.

Os resultados obtidos neste trabalho pela rede neural perceptron multicamadas sugere que a utilização de modelos utilizando redes neurais é capaz de obter resultados superiores aos dos modelos semi-empíricos mais utilizados, tendo um custo computacional adicional mínimo comparado ao custo-benefício obtido.

Palavras-chave: Redes *Wireless Indoor*. Modelos de Propagação. Redes Neurais. Predição do Sinal.

ABSTRACT

The focus of this study was to find a model for the signal propagation in indoor wireless networks. The formulation of models for this type of system, due to several existing features (such as layout of the environment between the transmitting and receiving antenna, the number of obstacles, of which the material is made obstacles, etc.), remains a problem difficult to solve, despite the variety of previous studies on the subject.

Models were developed for propagation through artificial neural networks, comparing the results obtained by them with the results of some of the semi-empirical models in the literature. In this sense, is seeking a model that best fits the characteristics of the target system, able to predict values at other points in the same environment.

The results of this work by the multilayer perceptron neural network suggests that the use of models using neural networks is able to achieve results superior to semi-empirical models used most, with a minimum additional computational cost compared to the cost-benefit.

Keywords: Indoor Wireless Network. Propagation Models. Neural Networks. Signal Prediction.

SUMÁRIO

AGRADECIMENTOS.....	i
RESUMO.....	ii
ABSTRACT.....	iii
LISTA DE FIGURAS.....	viii
LISTA DE TABELAS.....	xi
1 INTRODUÇÃO.....	1
2 PROPAGAÇÃO DE ONDAS DE RÁDIO.....	3
2.1 Introdução.....	3
2.2 Mecanismos e Efeitos de Propagação.....	4
2.2.1 Reflexão, Difração, Refração e Espalhamento.....	4
2.2.2 Dependência com a Distância.....	5
2.2.3 Variabilidade.....	5
2.2.4 Multipercursos.....	6
2.2.5 Perda de Penetração.....	6
2.3 Modelos de Propagação.....	7
2.3.1 Espaço Livre.....	8
2.3.2 Log-distance.....	9
2.3.3 Atenuação Linear.....	10
2.3.4 ITU-R P.1238-1.....	10
2.3.5 COST 231 Keenan e Motley.....	12

2.3.6	COST 231 Multi-Wall.....	13
2.4	Conclusão.....	13
3	REDES NEURAIS ARTIFICIAIS.....	14
3.1	Introdução.....	14
3.2	O Cérebro Humano.....	15
3.3	Neurônio Biológico.....	16
3.4	Modelo de um Neurônio.....	17
3.5	Funções de Ativação.....	19
3.5.1	Função Degrau.....	19
3.5.2	Função Sinal.....	20
3.5.3	Função Linear por Partes.....	21
3.5.4	Função Sigmóide Logística.....	21
3.5.5	Função Tangente Hiperbólica.....	23
3.6	Principais Arquiteturas de Redes Neurais.....	25
3.6.1	Redes Alimentadas Adiante com Camada Única.....	25
3.6.2	Redes Alimentadas Diretamente com Múltiplas Camadas.....	26
3.6.3	Redes Recorrentes.....	27
3.7	Aprendizado.....	27
3.7.1	Aprendizagem Supervisionada.....	29
3.7.2	Aprendizagem Não-Supervisionada.....	30
3.8	Modelos de Redes Neurais.....	30
3.8.1	Perceptron Simples.....	31
3.8.1.1	Algoritmo de Aprendizagem.....	31

3.8.2	Perceptron Multicamadas.....	34
3.8.2.1	Algoritmo de Aprendizagem.....	35
3.9	Conclusão.....	40
4	PREDIÇÃO DO SINAL ATRAVÉS DE REDES NEURAI.....	41
4.1	Introdução.....	41
4.2	Equipamento Utilizados para Medidas de Propagação.....	42
4.3	Medidas de Propagação.....	43
4.4	Modelos Projetados.....	44
4.4.1	Modelo do Espaço Livre Adaptado.....	44
4.4.2	Modelo por Atenuação Linear.....	45
4.4.3	Modelo COST 231 Keenan e Motley.....	45
4.4.4	Rede Neural Perceptron Simples.....	46
4.4.5	Rede Neural Perceptron Multicamadas.....	48
4.5	Simulação.....	48
4.6	Resultados Obtidos.....	50
4.6.1	Primeira Simulação Geral.....	52
4.6.2	Segunda Simulação Geral.....	55
4.6.3	Terceira Simulação Geral.....	58
4.7	Análise dos Resultados.....	61
4.7.1	Primeira Simulação Geral.....	61
4.7.2	Segunda Simulação Geral.....	62
4.7.3	Terceira Simulação Geral.....	63
4.7.4	Síntese dos Resultados.....	64

5 CONCLUSÃO.....	65
APÊNDICES	
1 Ferramenta de Simulação.....	67
REFERÊNCIAS BIBLIOGRÁFICAS.....	76

LISTA DE FIGURAS

2.1	Variabilidade de pequena e larga escala.....	6
3.1	Representação em diagrama de blocos do sistema nervoso.....	16
3.2	Neurônio biológico.....	17
3.3	Modelo de um neurônio.....	18
3.4	Função degrau.....	19
3.5	Função sinal.....	20
3.6	Função linear por partes.....	21
3.7	Função sigmóide logística.....	22
3.8	Função tangente hiperbólica.....	23
3.9	Rede alimentada adiante com uma única camada de saída.....	25
3.10	Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída.....	27
3.11	Rede recorrente.....	28
3.12	Aprendizagem supervisionada representada em diagrama de blocos.....	29
3.13	Aprendizagem não-supervisionada representada em diagrama de blocos..	30
3.14	Linha de decisão para perceptron simples com duas variáveis de entrada.	32
3.15	Rede MLP com uma camada oculta.....	35
4.1	Amostras de propagação obtidas mostradas mostradas em um plano x por y.....	47
4.2	10 gráficos do erro quadrático médio versus o número de neurônios na camada oculta.....	51

4.3	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado.....	52
4.4	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear.....	52
4.5	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley.....	53
4.6	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Simples.....	53
4.7	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Multicamadas.....	54
4.8	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado.....	55
4.9	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear.....	55
4.10	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley.....	56
4.11	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Simples.....	56
4.12	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Multicamadas.....	57
4.13	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado.....	58
4.14	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear.....	58
4.15	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley.....	59

4.16	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Simples.....	59
4.17	Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Multicamadas.....	60
A.1	Interface com o usuário do programa para simulação dos modelos criados	69
A.2	Valores de potência gerados pelo modelo através da rede neural perceptron multicamadas para o quarto 1, banheiro e sala.....	70
A.3	Valores de potência gerados pelo modelo através da rede neural perceptron multicamadas para o corredor, quarto 2, quarto 3 e cozinha.....	71
A.4	Erros do valor de potência gerados pelo modelo através da rede neural perceptron multicamadas para o quarto 1, banheiro e sala.....	72
A.5	Erros do valor de potência gerados pelo modelo através da rede neural perceptron multicamadas para o corredor, quarto 2, quarto 3 e cozinha.....	73
A.6	Erro absoluto das amostras em ordem crescente gerados pelo modelo através da rede neural perceptron multicamadas para a fase de treinamento e para a fase de teste.....	74
A.7	Histograma do erro absoluto de cada amostra gerado pelo modelo através da rede neural perceptron multicamadas para a fase de treinamento e para a fase de teste.....	75

LISTA DE TABELAS

2.1	Perdas de penetração em obstáculos.....	7
2.2	Constante de atenuação linear.....	10
2.3	Coeficiente de atenuação pela distância.....	11
2.4	Coeficiente de atenuação por andar.....	12
2.5	Desvio padrão da variável log-normal responsável pelo sombreamento.....	12
4.1	Estatísticas dos modelos obtidas para a primeira simulação geral.....	54
4.2	Estatísticas dos modelos obtidas para a segunda simulação geral.....	57
4.3	Estatísticas dos modelos obtidas para a terceira simulação geral.....	60

1 INTRODUÇÃO

As *Wireless Local Area Networks* (WLANs) estão atualmente no centro do processo de crescimento das redes sem fios. Estes sistemas introduzem um novo sentido às definições de banda larga em redes de rádio e ao conceito de flexibilidade de implementação em redes de comunicações. Apesar do importante papel que hoje em dia já desempenham, o processo de implementação ainda não é baseado num método rigoroso de planeamento, mesmo em ambientes *indoor*. Não é pouco comum se observar a instalação de grandes redes WLAN, com números consideráveis de Pontos de Acesso (PAs), com base em métodos empíricos como simples medidas de “alcance do sinal”. Este tipo de procedimento acarreta problemas importantes, como o não aproveitamento do potencial de cobertura do sistema à disposição e a nula análise da interferência [1].

No presente trabalho, são propostos dois modelos de preditores de cobertura de sinal através de redes neurais artificiais (RNA), buscando contribuir para uma melhor compreensão física da propagação de ondas de rádio em ambientes *indoor* e apresentar desenvolvimentos e implementações de modelos melhorados de predição de perda de propagação para tais ambientes. Os modelos de predição de perda de propagação foram os seguintes: (i) modelo através de uma rede neural perceptron simples, a qual utiliza um único neurônio e, de forma linear, tenta formar um modelo consistente, e (ii) modelo através de uma rede neural perceptron multicamadas, utilizando duas camadas, uma oculta e outra de saída, operando de forma não linear. A validação desses modelos foi realizada a partir de comparações dos resultados obtidos com o banco de dados de medidas realizadas no ambiente alvo e com modelos de propagação semi-empíricos tradicionais.

A solução de problemas através de redes neurais é bastante atrativa, já

que a forma como tais problemas são representados internamente pela rede e o paralelismo natural inerente à arquitetura dessas redes criam a possibilidade de um desempenho superior ao dos modelos convencionais. Em redes neurais, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem ou treinamento, em que um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida. Estas características são utilizadas posteriormente para gerar respostas para o problema. As redes neurais são capazes de extrair informações não apresentadas de forma explícita através dos exemplos utilizados no treinamento [5].

A principal justificativa da realização de trabalhos de predição de propagação de cobertura de ondas de rádio é a minimização do custo de planejamento e de implementação de sistemas de comunicação sem fio, fixo ou móvel, *indoor* ou *outdoor*. Obtendo-se modelos preditores confiáveis, diminui-se consideravelmente o número de amostras necessárias a serem obtidas do ambiente, implicando em uma diminuição de tempo e custo de projeto.

No capítulo 2, temos um breve resumo da propagação de ondas de rádio, para a fundamentação do problema inerente ao trabalho. No capítulo 3, detalhamos o funcionamento das redes neurais artificiais, suas principais características e aspectos para concepção de projetos das mesmas. No capítulo 4, ocorre o detalhamento das etapas para a realização do presente trabalho, desde a etapa da campanha de medidas, passando pela análise dos modelos utilizados para validação e modelos projetados, concluindo com os resultados obtidos e sua análise. A conclusão do trabalho e os possíveis pontos para pesquisas futuras são realizadas no capítulo 5. Há ainda uma descrição da ferramenta criada para simulação presente no apêndice deste trabalho.

2 PROPAGAÇÃO DE ONDAS DE RÁDIO

2.1 Introdução

O conhecimento do meio de transmissão é indispensável quando se objetiva realizar um bom planejamento de cobertura e desempenho radioelétrico. Nos sistemas *wireless*, o meio de propagação é o canal de rádio, cujas características e efeitos sobre a informação trafegada são de natureza complexa, impossibilitando uma análise completamente determinística, sugerindo assim a utilização de dados experimentais [6].

Existem vários e complexos mecanismos de propagação e todos eles têm influência direta na trajetória do sinal de rádio. Efeitos como a difração e a reflexão ocorrem quando uma onda rádio encontra um obstáculo de dimensões consideravelmente superiores ao seu comprimento de onda. Se os obstáculos são de dimensões comparáveis ou inferiores ao comprimento de onda, surge o espalhamento. Existem ainda mecanismos como a refração e fenômenos particulares como o efeito de onda guiada, bem como a capacidade de atravessar obstáculos. Em conjunto, provocam multipercurso e atenuação entre o emissor e o receptor, influenciando a fase, a amplitude e a direção da onda. Os modelos de propagação, partindo destes conhecimentos, estimam o valor das perdas de propagação, o que é fundamental para uma correta escolha do posicionamento de cada Ponto de Acesso [1].

Nas próximas seções, veremos algumas características de propagação no canal de rádio e, em seguida, alguns dos modelos de propagação existentes na literatura técnica para ambientes *indoor*.

2.2 Mecanismos e Efeitos de Propagação

A seguir, veremos alguns dos principais mecanismos da propagação e alguns efeitos causados por esses mecanismos.

2.2.1 Reflexão, Difração, Refração e Espalhamento

Nesta seção, apresentaremos os quatro principais mecanismos de propagação, que ocorrem devido a presença de obstáculos no percurso de propagação do sinal. Os mecanismos são:

- Reflexão – ocorre quando a onda de rádio incide sobre obstáculos cujas dimensões são consideravelmente maiores que o comprimento de onda do sinal incidente. O feixe de onda é refletido com oposição de fase em relação ao sinal direto, podendo causar atenuação do sinal.
- Refração – ocorre quando uma onda atravessa um meio de densidade diferente do meio em que se propagava, resultando em uma onda refletida e outra refratada, continuando o percurso através do novo meio, mas em uma diferente direção.
- Difração – ocorre quando o percurso de uma onda é obstruído por um obstáculo de superfície irregular ou pela extremidade do mesmo, cujas dimensões são consideravelmente maiores que o comprimento de onda do sinal (consequentemente, é dependente da frequência do sinal). É um mecanismo muito útil, visto que permite a recepção dos sinais de rádio quando as condições de linha de visada (LoS) não são satisfeitas.
- Espalhamento – ocorre quando o trajeto de propagação contém obstáculos cujas dimensões são compatíveis ao comprimento de onda do sinal. Possui natureza similar à difração, exceto pelo maior número de direções de dispersão do sinal. Conjuntamente com a difração, permite a recepção dos sinais em casos de ausência de linha de visada (NLoS).

2.2.2 Dependência com a Distância

O sinal de rádio tem seu nível de potência atenuado à medida que se propaga no canal, fato que ocorre devido ao espalhamento e à difração sofrida pelo sinal no espaço, reduzindo sua densidade de potência. Para ambientes amplos e sem obstáculo, como o espaço livre, a dependência da potência do sinal com a distância é uma relação quadrática, mas a medida que o número de obstáculos entre o transmissor e o receptor aumenta, esta relação com a distância acentua-se.

O objetivo dos modelos empíricos de propagação é ajustar a atenuação com a distância aos valores medidos, para obtermos uma previsão mediana do sinal realista. A variação do nível de potência do sinal recebido em relação a este nível mediano do sinal é caracterizada pelas variabilidades de pequena e larga escala [6].

2.2.3 Variabilidade

O sinal medido em um determinado ponto não é constante. Ele, na verdade, possui um valor médio e ocorre uma variação do sinal em torno desse valor médio. Essa variabilidade do sinal pode ser classificada em dois gêneros:

- Variabilidade de larga escala – também conhecida como sombreamento, está associada a flutuações do nível de potência do sinal em torno do seu valor médio, em razão das características do relevo e da morfologia do ambiente [6].
- Variabilidade de pequena escala – é causado por raios provenientes do transmissor que chegam ao receptor por caminhos diferentes (multipercursos). Estes diferentes caminhos implicam que os sinais cheguem ao receptor com amplitudes e fases diferentes [6]. Este tipo de variabilidade também é conhecida como desvanecimento rápido, atuando de forma muito rápida no canal, podendo causar interferências construtivas no sinal recebido, ampliando sua potência, como interferências destrutivas, causando desvanecimentos profundos no sinal recebido.

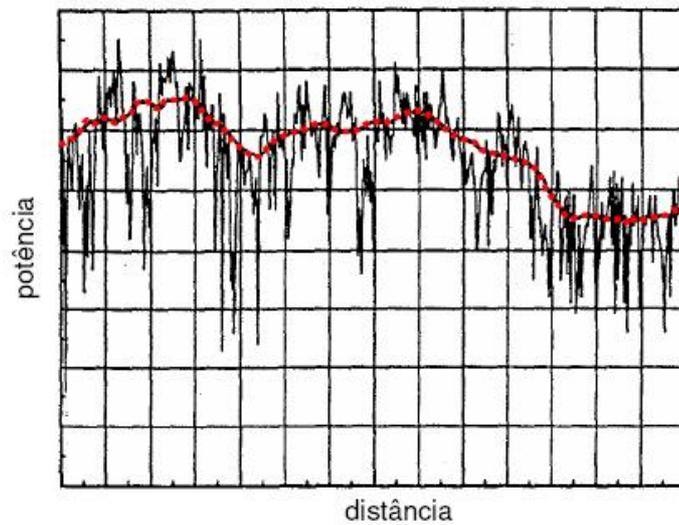


Figura 2.1: Variabilidade de pequena (preto) e larga escala(vermelho)

2.2.4 Multipercursos

O efeito de multipercurso é causado por três mecanismos de propagação: a reflexão, a difração e o espalhamento. Estes fenômenos permitem que um sinal atinja um destino por diferentes percursos, além do percurso com LoS, quando este existe. A interseção destes raios faz com que o sinal no dado ponto no espaço seja composto pelos diversos sinais de modo construtivo, isto é, aumentando o nível de potência do sinal, ou de modo destrutivo, diminuindo o nível de potência do sinal.

2.2.5 Perda de Penetração

Quando um sinal que está propagando incide sobre uma determinada superfície (parede, piso, etc), pode ocorrer qualquer um dos mecanismos de propagação citados anteriormente. Dependendo do material deste obstáculo, de sua forma e de suas dimensões, o sinal propagante pode penetrar através do mesmo havendo uma perda devido a penetração.

A tabela seguinte apresenta valores de perda de penetração medidos (pelo European COST 231) para obstáculos mais comuns em ambientes fechados, para a frequência de 2.4 GHz.

Obstáculo	Perda adicional [dB]
Espaço livre	0
Janela (tinta não-metálica)	3
Janela (tinta metálica)	5 a 8
Parede fina (madeira)	5 a 8
Parede média (madeira)	10
Parede espessa (aproximadamente 15 cm)	15 a 20
Parede muito espessa (aproximadamente 30 cm)	20 a 25
Piso/Teto espesso	15 a 20
Piso/Teto muito espesso	20 a 25

Tabela 2.1: Perdas de penetração em obstáculos

2.3 Modelos de Propagação

Um modelo de propagação é determinado por expressões matemáticas, diagramas e algoritmos usados para representar as características de um sistema de rádio de acordo com o ambiente. Geralmente, os modelos de predição podem ser classificados como empíricos (ou estatísticos), teóricos (ou determinísticos) ou a combinação dos dois (semi-empíricos). Os modelos empíricos são baseados em medidas e dados estatísticos, já os modelos teóricos tratam dos princípios fundamentais dos fenômenos de propagação das ondas de rádio [7].

Na literatura, é possível encontrar vários modelos básicos, tal como o modelo de Espaço Livre, sendo este a base de todos os modelos empíricos e semi-empíricos. Há o modelo Log-distance, semelhante ao modelo de Espaço Livre, com uma modificação no coeficiente de perda de percurso. Tem-se também o modelo por Atenuação Linear, que considera uma relação linear entre a distância e o índice de decaimento médio de potência, n . O modelo de Keenan e Motley contabiliza a atenuação de pisos e paredes. O modelo ITU-R P.1238-1 para interiores é proposto pela International Telecommunications Union (ITU), apresentando uma dependência do tipo de ambiente e contabilizando a atenuação causada pelos pisos, mas não a causada pelas paredes. O modelo COST 231 Multi-Wall para interiores incorpora a atenuação por paredes e pisos, semelhante ao modelo de Keenan e Motley, mas considera um comportamento não linear da atenuação através dos pisos.

A seguir, veremos mais detalhadamente alguns dos modelos citados acima.

2.3.1 Espaço Livre

O modelo de propagação no espaço livre é utilizado para prever a amplitude do sinal recebido quando o transmissor e o receptor estão em um meio onde não há obstrução da linha de visada direta entre as duas antenas. Os sistemas de comunicações via satélite e os enlaces terrestres de microondas são exemplos típicos onde se pode empregar esse modelo de propagação. De acordo com a fórmula de Friis, temos que:

$$P_R = P_T G_T G_R \left(\frac{\lambda}{4\pi d} \right)^2 \quad (2.1)$$

onde:

- P_R – potência recebida
- P_T – potência transmitida
- G_T – ganho da antena transmissora
- G_R – ganho da antena receptora
- λ – comprimento de onda
- d – distância entre o transmissor e o receptor (em metros)

A atenuação sofrida pelo sinal (perda de propagação), medida em dB, é definida por:

$$L_{total}(dB) = 10 \log\left(\frac{P_T}{P_R}\right) = -10 \log\left(\frac{G_T G_R \lambda^2}{(4\pi d)^2}\right) \quad (2.2)$$

Se utilizarmos antenas omnidirecionais tanto na transmissão quanto na recepção ($G_T = G_R = 0$, em dB), teremos:

$$L_{total}(dB) = 10 \log\left(\frac{P_T}{P_R}\right) = -20 \log\left(\frac{\lambda}{4\pi d}\right) \quad (2.3)$$

$$L_{total}(dB) = -20 \log\left(\frac{c/f}{4\pi d}\right) = -20 \log\left(\frac{(3 * 10^8)/(f * 10^6)}{4\pi d}\right) \quad (2.4)$$

$$L_{total}(dB) = -27.56 + 20 \log(f) + 20 \log(d) \quad (2.5)$$

onde $c = 3 \cdot 10^8$ m/s é a velocidade da luz e f é a frequência (em MHz).

Logo, o sinal recebido através deste modelo de propagação, em dB, será:

$$P_R = P_T + 27.56 - 20 \log(f) - 20 \log(d) \quad (2.6)$$

A fórmula de Friis é usada somente nos casos em que o receptor esteja localizado em uma região de campo distante em relação ao transmissor. A distância mínima, d_F , para se considerar a situação de campo distante pode ser calculada através da equação a seguir, em que D é a maior dimensão linear física da antena [7].

$$d_F = \frac{2D^2}{\lambda} \quad (2.7)$$

2.3.2 Log-distance

São os modelos mais simples utilizados para a perda de propagação em ambientes *indoor* ou micro-células em ambientes *outdoor*. Podem ser representados na forma geral:

$$L_{total}(dB) = L_0 + 10n \cdot \log(d/d_0) + X_\sigma \quad (2.8)$$

onde L_{total} é a perda de propagação total, L_0 é a perda de propagação à uma distância d_0 , d é a distância entre o transmissor e o receptor, n é o coeficiente de perda de percurso e X_σ é a variabilidade de larga escala. O coeficiente de propagação n e X_σ são variantes quanto ao ambiente de propagação e a frequência utilizada pelo sistema, sendo encontrados valores tabelados na literatura.

Em geral, utiliza-se $d_0 = 1$ metro, fazendo com que a expressão se resuma à:

$$L_{total}(dB) = L_{d_0=1} + 10n \cdot \log(d) + X_\sigma \quad (2.9)$$

Consequentemente, a potência recebida, em dB, será:

$$P_R = P_T - L_{d_0=1} - 10n \cdot \log(d) - X_\sigma \quad (2.10)$$

2.3.3 Atenuação Linear

Consiste numa modificação proposta no modelo log-distance, incluindo agora uma perda linear de propagação proporcional à distância por um fator α . A perda de propagação no modelo consiste em:

$$L_{total}(dB) = L_0 + 10n \cdot \log(d/d_0) + \alpha d + X_\sigma \quad (2.11)$$

onde α é uma perda de propagação linear (medida em dB/m), dependente do ambiente e da frequência do sistema, e os outros parâmetros já foram especificados no modelo log-distance.

A potência recebida, utilizando uma distância $d_0 = 1$ metro, será:

$$P_R = P_T - L_{d_0=1} - 10n \cdot \log(d) - \alpha d - X_\sigma \quad (2.12)$$

Abaixo temos uma tabela com alguns valores de α encontrados na literatura:

Local	Frequência	α (dB/m)
Ambiente com 4 cômodos	850 MHz	0.62
	1.7 GHz	0.57
	4.0 GHz	0.47
Ambiente com 2 cômodos	850 MHz	0.48
	1.7 GHz	0.35
	4.0 GHz	0.23

Tabela 2.2: Constante de atenuação linear

2.3.4 ITU-R P.1238-1

Modelo de propagação desenvolvido pelo Radiocommunication Sector do International Telecommunication Union (ITU), para ambientes *indoor* que operem em uma faixa de frequências de 900 MHz a 100 GHz.

Considera os seguintes efeitos de propagação [6]:

- Reflexão e difração em objetos fixos;
- Transmissão através de pisos e outros obstáculos fixos;
- Confinamento da energia em corredores;
- Pessoas e objetos em movimento no ambiente;

Abaixo temos a expressão para a perda de propagação para este modelo:

$$L_{total}(dB) = 20 \log(f) + n \cdot \log(d) + L_f(K_f) - 28 + X_\sigma \quad (2.13)$$

onde:

- f – frequência de operação do sistema
- n – coeficiente de atenuação pela distância
- d – distância entre o transmissor e o receptor em metros
- k_f – número de pisos (andares) atravessados
- L_f – coeficiente de atenuação por andar dependente do número de andares [dB].
- X_σ - variabilidade de larga escala (sombreamento)

Logo, o sinal recebido, em dB, por este modelo é definido por:

$$P_R = P_T - 20 \log(f) - n \cdot \log(d) - L_f(K_f) + 28 - X_\sigma \quad (2.14)$$

A seguir, veremos as tabelas com alguns valores para o coeficiente de atenuação pela distância, para o coeficiente de atenuação por piso atravessado e o desvio padrão da variabilidade de larga escala (sombreamento/desvanecimento lento):

Frequência	Residencial	Escritório	Comercial
900 MHz	-	33	20
1.2 – 1.3 GHz	-	32	22
1.8 – 2.0 GHz	28	30	22
4 GHz	-	28	22
5 GHz	-	31	-

Tabela 2.3: Coeficiente de atenuação pela distância

Frequência	Residencial	Escritório	Comercial
900 MHz	-	9 (1 andar)	-
		19 (2 andares)	
		24 (3 andares)	
1.8 – 2.0 GHz	4 k _f	15 + 4(k _f - 1)	6 + 3(k _f - 1)
5.2 GHz	-	16 (1 andar)	-

Tabela 2.4: Coeficiente de atenuação por andar

Frequência	Residencial	Escritório	Comercial
1.8 – 2.0 GHz	8	10	10
5.2 GHz	-	12	-

Tabela 2.5: Desvio padrão da variável log-normal responsável pelo sombreamento

2.3.5 COST 231 Keenan e Motley

Um dos modelos mais complexos para a predição do sinal em ambientes *indoor* e *outdoor* com obstáculos. Requer uma grande quantidade de características do ambiente de propagação e do percurso entre o transmissor e cada ponto onde pode estar o receptor, tornando-se o mais abrangente dos modelos. É definido por:

$$L_{total}(dB) = L_0 + 10n \cdot \log(d) + \sum_{i=1}^I K_{f,i} L_{f,i} + \sum_{j=1}^J K_{w,j} L_{w,j} \quad (2.15)$$

onde:

- L₀ – perda de propagação a um metro da antena transmissora
- n – coeficiente de atenuação pela distância
- d – distância entre o transmissor e o receptor e metros
- K_{f,i} – número de pisos com a mesma características
- L_{f,i} – perda de propagação do sinal através do piso i [dB]
- K_{w,j} – número de paredes com a mesma características
- L_{w,j} – perda de propagação do sinal através da parede j [dB]
- I – número total de pisos com características diferentes atravessados pelo sinal
- J – número total de paredes com características diferentes atravessadas pelo

sinal

2.3.6 COST 231 Multi-Wall

Este modelo considera a perda propagação pelo espaço livre adicionada da perda de penetração em paredes (tal qual o modelo COST231 Keenan e Motley) e da perda de penetração através de pisos, mas, ao contrário do modelo anterior, de forma não linear, de acordo com o que foi observado nos estudos realizados. Abaixo segue sua expressão:

$$L_{total}(dB) = L_0 + 10n \log(d) + k_f^{\left[\frac{k_f+2}{k_f+1} - b\right]} L_f + \sum_{j=1}^J K_{w,j} L_{w,j} \quad (2.16)$$

onde:

- L_0 – perda de propagação a um metro da antena transmissora
- n – coeficiente de atenuação pela distância
- d – distância entre o transmissor e o receptor e metros
- $K_{w,j}$ – número de paredes com a mesma características
- $L_{w,j}$ – perda de propagação do sinal através da parede j [dB]
- J – número total de paredes com características diferentes atravessadas pelo sinal
- K_f – número de pisos atravessados pelo sinal
- L_f – perda de propagação do sinal através dos pisos [dB]

2.4 Conclusão

Neste capítulo, foram apresentados os principais mecanismos e efeitos de propagação, bem como alguns dos principais modelos semi-empíricos existentes na literatura. Este conhecimento é necessário para o desenvolvimento de programas computacionais dedicados à predição da propagação das ondas de rádio para alguns desses modelos com a finalidade de se validar os resultados obtidos pelos modelos propostos no presente trabalho.

3 REDES NEURAIS ARTIFICIAIS

3.1 Introdução

O ser humano é dotado de complexos circuitos neurais cerebrais que constam de variadas conexões entre seus neurônios, onde essas conexões são conhecidas como sinapses. As sinapses interagem entre si de modo a fazer emergir o comportamento inteligente. Sendo assim, se for possível modelar computacionalmente essas conexões neurais, surge a idéia de que também será possível fazer emergir comportamentos inteligentes em máquinas. Nesse contexto, surgem as redes neurais artificiais (RNAs), geralmente denominadas “redes neurais”, que são inspiradas na própria natureza das redes de neurônios e sinapses biológicas [3].

O cérebro humano é um sistema de processamento de informação altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos muito mais rapidamente que o mais veloz computador digital existente hoje. A rede de nodos do cérebro humano tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência, além de interpretar observações. Apesar do estudo contínuo, o funcionamento das redes biológicas ainda não foi totalmente desvendado pelo homem. Não se sabe ao certo a forma como as funções cerebrais são realizadas. O que se tem até o momento são modelos, os quais são atualizados a cada nova descoberta. No entanto, a estrutura fisiológica básica das redes de nodos naturais é conhecida, e é exatamente nessa estrutura fisiológica que se baseiam as RNAs [2].

Podemos então definir uma rede neural como um processador

maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo desejado, para que a rede neural “aprenda” o modo de funcionamento do sistema.

A modificação dos pesos sinápticos é o método tradicional para o projeto de redes neurais (e o método utilizado neste projeto). Esta abordagem é bastante próxima da teoria dos filtros adaptativos lineares, bastante aplicada em diversas áreas, como, por exemplo, em telecomunicações. Entretanto, é possível também para uma rede neural modificar sua própria topologia, o que é motivado pelo fato de os neurônios do cérebro humano poderem morrer e que novas conexões sinápticas possam crescer [4].

3.2 O Cérebro Humano

O sistema nervoso humano pode ser visto como um sistema de três estágios. O centro do sistema nervoso é o cérebro (representado pela rede neural na figura 3.1), responsável por receber informações e tomar decisões diante das informações recebidas. Observando a figura 3.1, observamos setas presentes nos dois sentidos do diagrama. As setas apontando da esquerda para a direita mostram o fluxo da informação no sistema, enquanto as setas apontando da direita para a esquerda indicam a presença de realimentação do sistema. Os receptores são responsáveis por converter os estímulos recebidos em impulsos elétricos e os atuadores convertem os impulsos nervosos gerados pelo cérebro em saída do

sistema [4].



Figura 3.1: Representação em diagrama de blocos do sistema nervoso

Após a introdução dos neurônios como constituintes estruturais do cérebro, o esforço para entendê-lo se tornou mais fácil. Tipicamente, os eventos de propagação em neurônios estão na ordem de milissegundos, ou seja, possuem uma frequência de operação na faixa dos KHz, a qual é uma frequência de operação baixa quando comparada com os processadores existentes hoje em dia. Entretanto, esta baixa taxa de operação é compensada pelo elevado número de neurônios existentes, com inúmeras conexões entre si. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses (parte do neurônio responsável pela propagação das informações). O resultado livre é que o cérebro é uma estrutura extremamente eficiente, capaz de resolver problemas complexos como reconhecimento de voz ou segmentação de imagens em intervalos de tempo muito superiores à muitos processadores com frequência de operação mais altas que as do neurônio.

3.3 Neurônio Biológico

Um neurônio típico é composto por um corpo celular ou soma, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos formam uma malha de filamentos finíssimas ao redor do neurônio, ao passo que o axônio consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, através da qual as informações se propagam. O número de sinapses recebidas por cada neurônio varia de 100 a 100.000, sendo que elas podem ser tanto excitatórias como inibitórias [3].

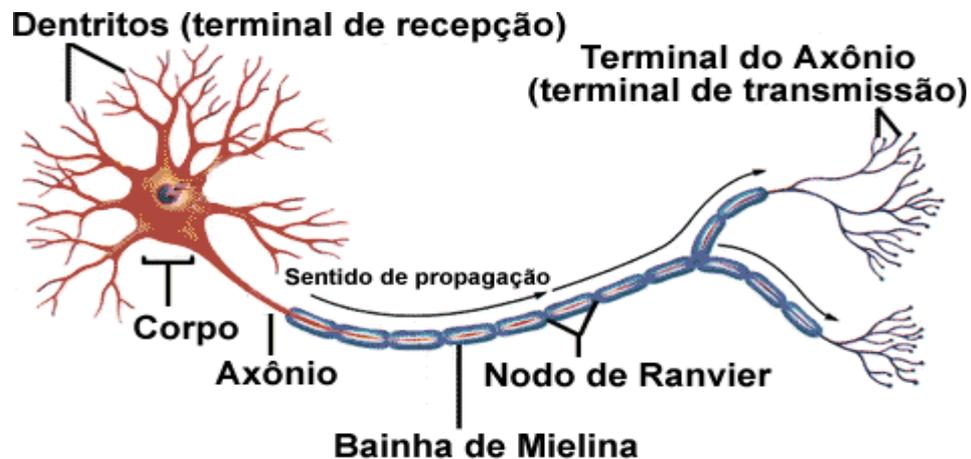


Figura 3.2: Neurônio biológico

O fluxo de informação ocorre sempre em um único sentido, que é dos dendritos para o corpo celular, desse para o axônio, seguindo para o próximo neurônio.

Os neurônios se unem funcionalmente pelas sinapses, formando redes neurais. As sinapses funcionam como válvulas e são capazes de controlar a transmissão de impulsos, isto é, o fluxo da informação, entre os nodos na rede neural. O efeito das sinapses é variável, e esta variação fornece ao neurônio a capacidade de adaptação. Os sinais oriundos dos neurônios pré-sinápticos são passados para o corpo do neurônio pós-sináptico, onde são comparados com os outros sinais recebidos pelo mesmo. Se o percentual em um intervalo curto de tempo é suficientemente alto, a célula dispara, produzindo um impulso que é transmitido para as células seguintes (nodos pós-sinápticos). Este sistema simples é responsável pela maioria das funções realizadas pelo cérebro. A capacidade de realizar funções complexas surge com a operação em paralelo de todos os aproximadamente 10^{11} nodos do cérebro humano [2].

3.4 Modelo de um Neurônio

O neurônio é a unidade de processamento que é fundamental para a

operação de uma rede neural.

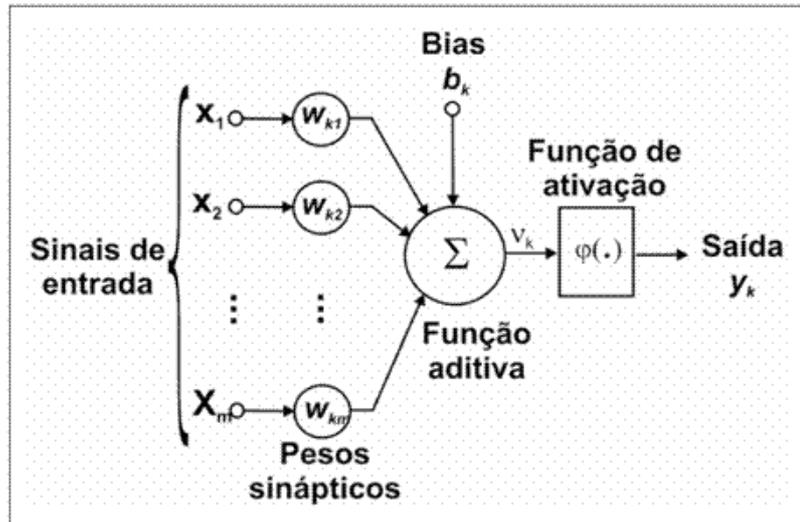


Figura 3.3: Modelo de um neurônio

A seguir, discutiremos os três elementos básicos do modelo do neurônio:

- O conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} . Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode ser tanto um valor positivo como um valor negativo.
- Um somador para os sinais de entrada ponderados pelas respectivas sinapses do neurônio; as operações descritas constituem um operador linear.
- Uma função de ativação para restringir a amplitude de saída do neurônio. A função de ativação é também referida como função restritiva uma vez que limita o intervalo de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo unitário fechado $[0, 1]$ ou, alternativamente, $[-1, 1]$ [4].

Além dos sinais de entrada ponderados pelos pesos sinápticos, também é entrada do somador um bias, representado na figura 1.3 por b_k . Este bias b_k aumenta ou diminui a entrada da função de ativação, dependendo do seu valor.

Observando a figura 3.3, podemos escrever as equações matemáticas:

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

e

$$y_k = \varphi(v_k + b_k) \quad (3.2)$$

onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; v_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi()$ é a função de ativação; e y_k é o sinal de saída do neurônio.

O bias é utilizado para se obter uma transformação afim à saída u_k do transformador linear, visto abaixo:

$$y_k = (v_k + b_k) \quad (3.3)$$

3.5 Funções de Ativação

3.5.1 Função Degrau

Para a função degrau, temos:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.4)$$

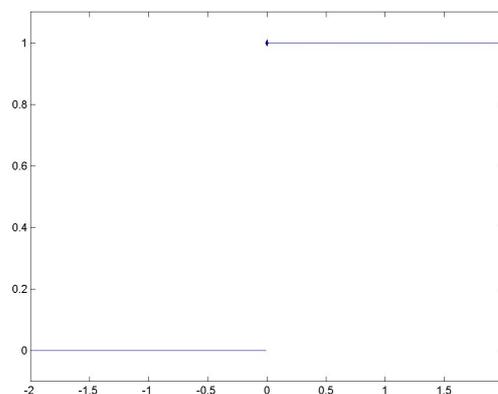


Figura 3.4: Função degrau

Para este caso, teremos o seguinte campo local induzido do neurônio:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.5)$$

Este neurônio é conhecido na literatura como modelo de McCulloch-Pitts, em reconhecimento ao trabalho de McCulloch e Pitts. Para este neurônio, só teremos saída de valor 0 ou valor 1.

3.5.2 Função Sinal

Para a função sinal, temos:

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ -1, & \text{se } v < 0 \\ 0, & \text{se } v = 0 \end{cases} \quad (3.6)$$

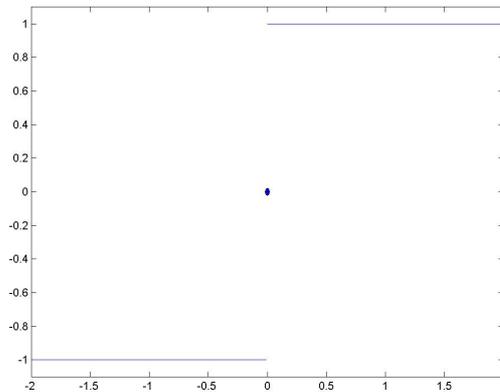


Figura 3.5: Função sinal

Para o uso específico como função de ativação, admite-se que quando $v = 0$, a saída terá valor -1 ou valor 1; portanto, somente dois valores para a saída.

3.5.3 Função Linear por Partes

Para a função linear por partes, temos:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 1 \\ v, & \text{se } -1 < v < 1 \\ 0, & \text{se } v < -1 \end{cases} \quad (3.7)$$

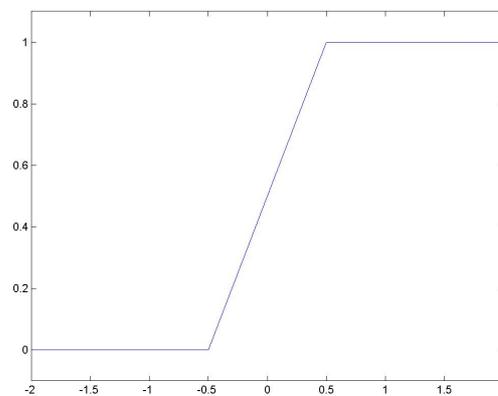


Figura 3.6: Função linear por partes

Neste caso, estamos assumindo que o fator de ampliação dentro da região linear de operação ($-1/2 < v < 1/2$) é a unidade.

3.5.4 Função Sigmóide Logística

Esta é a forma mais comum de função de ativação utilizada na construção de redes neurais artificiais. É uma função estritamente crescente e não-linear. É definida por:

$$\varphi = \frac{1}{(1 + e^{-av})} \quad (3.8)$$

onde “a” é o parâmetro de inclinação da função, que deve ser sempre positivo.

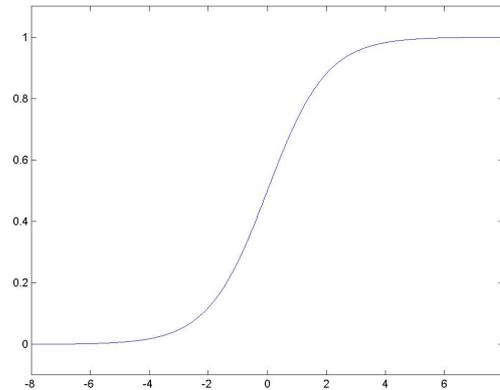


Figura 3.7: Função Sigmóide Logística

Há dois aspectos importantes para se observar quanto a função sigmóide logística:

- É uma função contínua com valor de saída pertencente ao intervalo $[0,1]$.
- É uma função diferenciável (característica importante para aprendizado de redes neurais), possuindo a facilidade de que o cálculo de sua derivada é realizado através de uma expressão que utiliza a própria função, facilitando o cálculo. Abaixo vemos o cálculo de sua derivada:

$$\frac{d \varphi(v)}{dv} = \left[\frac{1}{(1 + e^{-av})} \right]' \quad (3.9)$$

$$\frac{d \varphi(v)}{dv} = \frac{-1(e^{-av})(-a)}{(1 + e^{-av})^2} \quad (3.10)$$

$$\frac{d \varphi(v)}{dv} = \frac{a(e^{-av})}{(1 + e^{-av})^2} \quad (3.11)$$

Sabendo que

$$\varphi(v)^2 = \frac{1}{(1 + e^{-av})^2} \quad (3.12)$$

e que

$$e^{-av} = \frac{1 - \varphi(v)}{\varphi(v)} \quad (3.13)$$

substituimos (3.12) e (3.13) em (3.11):

$$\frac{d\varphi(v)}{dv} = \varphi(v)^2 a \frac{1 - \varphi(v)}{\varphi(v)} \quad (3.14)$$

$$\frac{d\varphi(v)}{dv} = \varphi(v) a (1 - \varphi(v)) \quad (3.15)$$

como queríamos demonstrar.

3.5.5 Função Tangente Hiperbólica

Esta é outra função de ativação bastante utilizada, com uma saída pertencente ao intervalo $[-1, 1]$. É definida por:

$$\varphi(v) = \frac{1 - e^{-av}}{1 + e^{-av}} \quad (3.16)$$

onde “a” é o parâmetro de inclinação da função, o qual deve ser sempre positivo.

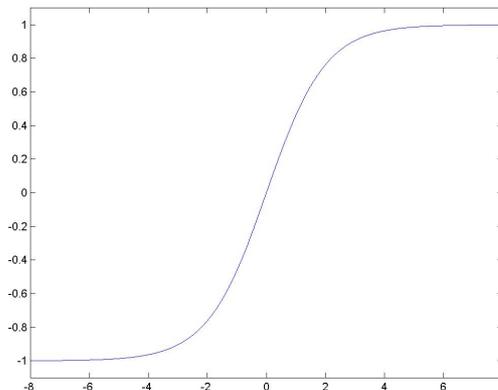


Figura 3.8: Função tangente hiperbólica

Assim como a função sigmóide logística, a função tangente hiperbólica também é uma função diferenciável que utiliza sua própria expressão para o cálculo da sua derivada, como veremos logo abaixo:

$$\frac{\varphi(v)}{dv} = \left[\frac{(1 - e^{-av})}{(1 + e^{-av})} \right], \quad (3.17)$$

$$\frac{d\varphi(v)}{dv} = \frac{-e^{-av}(-a)(1 + e^{-av}) - (1 - e^{-av})e^{-av}(-a)}{(1 + e^{-av})^2} \quad (3.18)$$

$$\frac{d\varphi(v)}{dv} = \frac{2ae^{-av}}{(1 + e^{-av})^2} \quad (3.19)$$

Sabendo que

$$e^{-av} = \frac{1 - \varphi(v)}{1 + \varphi(v)} \quad (3.20)$$

e que

$$\frac{1}{1 + e^{-av}} = \frac{\varphi(v)}{1 - e^{-av}} \quad (3.21)$$

substituímos (3.20) e (3.21) em (3.19):

$$\frac{d\varphi(v)}{dv} = 2a \frac{1 - \varphi(v)}{1 + \varphi(v)} \left[\frac{(\varphi(v))}{1 - \frac{1 - \varphi(v)}{1 + \varphi(v)}} \right]^2 \quad (3.22)$$

$$\frac{d\varphi(v)}{dv} = 2a \frac{1 - \varphi(v)}{1 + \varphi(v)} \varphi(v)^2 \left[\frac{1 + \varphi(v)}{2\varphi(v)} \right]^2 \quad (3.23)$$

$$\frac{d\varphi(v)}{dv} = 2a(1 - \varphi(v)) \frac{(1 + \varphi(v))}{4} \quad (3.24)$$

$$\frac{d\varphi(v)}{dv} = 0.5a(1 - \varphi(v)^2) \quad (3.25)$$

como queríamos demonstrar.

3.6 Principais Arquiteturas de Redes Neurais

Em geral, podemos identificar três classes de arquiteturas de rede fundamentalmente diferentes:

3.6.1 Redes Alimentadas Adiante com Camada Única

Em uma rede neural em camadas, os neurônios estão organizados, obviamente, na forma de camadas. Na forma mais simples de uma rede em camadas, temos uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios (nós computacionais), mas não vice-versa. Em outras palavras, esta rede é estritamente do tipo alimentada adiante ou acíclica. Esta rede é chamada de rede de camada única, sendo que a designação “única” se refere à camada de saída de nós computacionais [4].

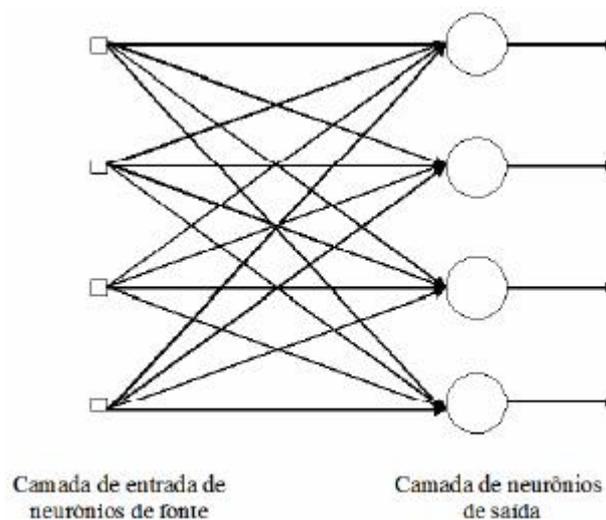


Figura 3.9: Rede alimentada adiante com uma única camada de saída

3.6.2 Redes Alimentadas Diretamente com Múltiplas Camadas

A segunda classe de uma rede neural alimentada adiante se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil. Adicionando-se uma ou mais camadas ocultas, a rede se torna capaz de extrair estatísticas de ordem elevada. Em um sentido bastante livre, a rede adquire uma perspectiva global apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais. A habilidade de os neurônios ocultos extraírem estatísticas de ordem elevada é particularmente valiosa quando o tamanho da camada de entrada é relativamente grande [4].

Os nós de fonte da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada, isto é, na primeira camada oculta. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede. Tipicamente, os neurônios em cada camada da rede têm como suas entradas apenas os sinais de saída da camada precedente. O conjunto de sinais de saída dos neurônios da camada de saída (final) da rede constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da camada de entrada (primeira)[2]. O grafo arquitetural na Figura 3.10 ilustra a planta de uma rede neural de múltiplas camadas alimentada adiante para o caso de uma única camada oculta, que possui 4 neurônios de fonte, 4 neurônios ocultos e 2 neurônios de saída. A rede ilustrada na Figura 3.10 é dita totalmente conectada, no sentido de que cada um dos nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte. Se alguns dos elos de comunicação (conexões sinápticas) estiverem faltando na rede, diz-se que a rede é parcialmente conectada.

3.6.3 Redes Recorrentes

Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios. Na estrutura representada na figura 3.11, não há laços de auto-realimentação na rede. Auto-realimentação se refere a uma situação onde a saída

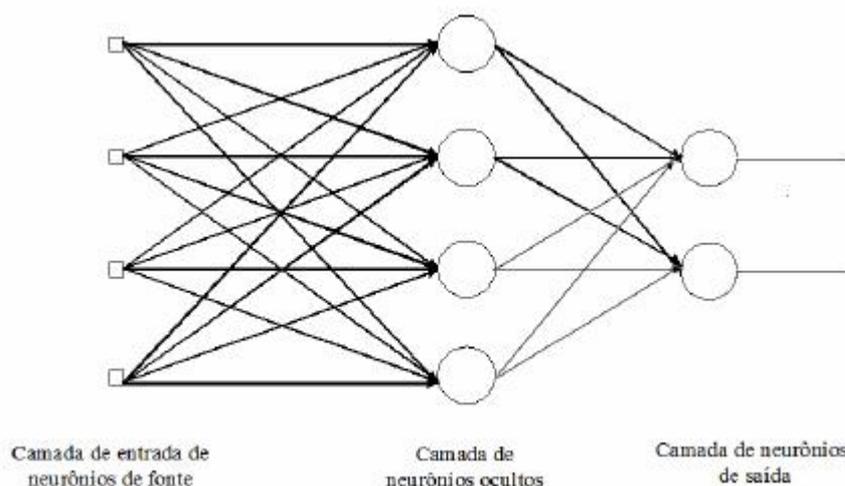


Figura 3.10: Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída

de um neurônio é realimentada para a sua própria entrada. No caso dessa figura, temos uma realimentação do único neurônio da camada de saída para um dos neurônios da camada anterior.

A presença de laços de realimentação tem um impacto significativo na capacidade de aprendizagem e no desempenho da rede. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitário, o que resulta em um comportamento dinâmico não-linear, admitindo-se que a rede neural contenha unidades não-lineares [4].

3.7 Aprendizado

As redes neurais artificiais possuem a capacidade de aprender por

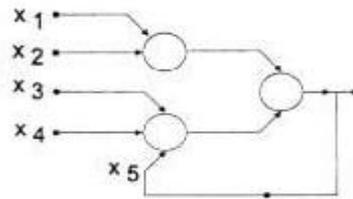


Figura 3.11: Rede recorrente

exemplos e fazer interpolações e extrapolações do que aprenderam. No aprendizado conexionista, não se procura obter regras como na abordagem simbólica da Inteligência Artificial, mas sim determinar a intensidade de conexões entre neurônios. Algoritmo de aprendizado é um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma rede neural para que a mesma possa aprender uma determinada função. Não há um único algoritmo de aprendizado. O que se tem é um conjunto de ferramentas representadas por diversos algoritmos, cada qual com suas vantagens e desvantagens. Estes algoritmos diferem, basicamente, pela maneira com a qual o ajuste dos pesos é feito [2].

A utilização de uma rede neural na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões apresentados a ela, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando [5].

No processo de aprendizagem, a seguinte sequência de eventos ocorre com a rede neural:

- A rede neural é estimulada pelo ambiente.
- A rede neural sofre modificações nos seus parâmetros como resultado desta estimulação.
- A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna [2].

Veremos agora mais detalhadamente dois dos paradigmas de aprendizagem mais utilizados.

3.7.1 Aprendizagem Supervisionada

Também conhecida como aprendizagem com um professor, é a estrutura de aprendizagem mais utilizada. Em termos conceituais, podemos considerar o professor como tendo conhecimento sobre o ambiente, com este conhecimento sendo representado por um conjunto de exemplos de entrada-saída. Entretanto, o ambiente é desconhecido pela rede neural de interesse. Supondo que o professor e a rede neural sejam expostos a um vetor de treinamento e sendo o professor capaz de fornecer à rede neural uma resposta desejada àquele vetor de treinamento devido ao seu conhecimento prévio, a rede neural terá seus parâmetros ajustados sob a influência combinada do vetor de treinamento e do vetor do sinal de erro (definido como a diferença entre a resposta desejada e a resposta real da rede). Este ajuste é realizado passo a passo, iterativamente, com o objetivo de fazer a rede neural emular o professor; supõe-se que a emulação seja ótima num sentido estatístico. Desta forma, o conhecimento do ambiente disponível ao professor é transferido para a rede neural através do treinamento. Quando um critério de avaliação é satisfeito, o professor pode ser dispensado e a rede neural passa a lidar com o ambiente por si mesma [4].

Esta forma de aprendizagem também é conhecida como aprendizagem por correção de erro, sendo um sistema realimentado de laço fechado, onde o ambiente desconhecido não está no laço.

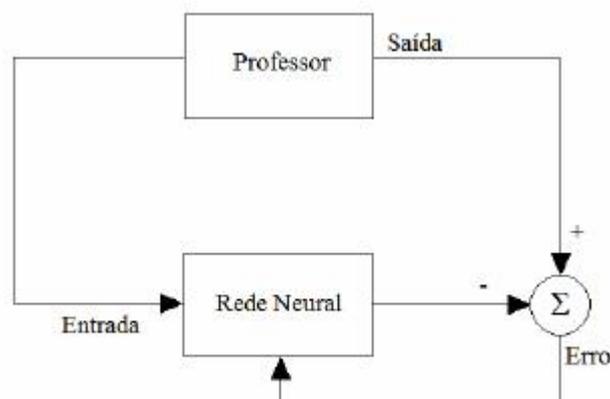


Figura 3.12: Aprendizagem supervisionada representada em diagrama de blocos

3.7.2 Aprendizagem Não-Supervisionada

Neste paradigma de aprendizagem, também conhecido como auto-organizada, não existe a figura de um professor para auxiliar o processo de aprendizado. Em vez disso, são dadas condições para realizar uma medida independente da tarefa da qualidade da representação que a rede deve aprender, e os parâmetros livre da rede são otimizados em relação a esta medida. Uma vez que a rede tenha se ajustado às regularidades estatísticas de dados de entrada, ela desenvolve a habilidade de formar representações internas para codificar as características da entrada e, desse modo, de criar automaticamente novas classes [4]. Muitos dos sistemas biológicos se desenvolvem através de aprendizado não-supervisionado, como, por exemplo, os estágios iniciais dos sistemas de visão e auditivo.

O aprendizado por competição é um caso particular de aprendizado não-supervisionado. Neste caso, para um dado padrão de entrada, as saídas competem entre si com o objetivo de serem ativadas e, dessa forma, seus pesos serão atualizados no treinamento. As unidades de entrada são diretamente conectadas às unidades de saída, que, por sua vez, podem estar ligadas entre si por meio de conexões laterais. A unidade de saída com maior ativação inicial terá maior chance de vencer a disputa das outras unidades. A unidade mais forte se torna ainda mais forte e seu efeito inibidor sobre todas as outras unidades torna-se dominante. Com o tempo, todas as outras unidades de saída ficarão completamente inativas, exceto a vencedora [2].

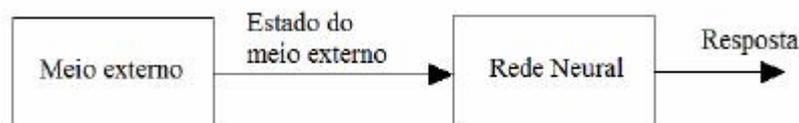


Figura 3.13: Aprendizagem não-supervisionada representada em diagrama de blocos

3.8 Modelos de Redes Neurais

A seguir, veremos detalhadamente os dois modelos de redes neurais que

foram utilizados nesta pesquisa.

3.8.1 Perceptron Simples

O perceptron simples é construído em torno de um neurônio linear. O nó aditivo do modelo do neurônio calcula uma combinação linear das entradas aplicadas às suas sinapses e também incorpora um bias aplicado externamente. A soma resultante é aplicada ao limitador abrupto (função sinal ou degrau). O neurônio produzirá na saída um conjunto 0 se a entrada do limitador for negativa e 1 se a entrada for positiva para a função degrau ou -1 se a entrada for negativa e 1 se a entrada for positiva para a função sinal.

O neurônio utilizado terá o mesmo formato do neurônio mostrado na figura 3.3. Logo, para um vetor de entradas de tamanho m , teremos:

$$v = \sum_{i=1}^m w_i x_i + b \quad (3.26)$$

O objetivo do perceptron simples é classificar corretamente o conjunto de estímulos aplicados externamente x_1, x_2, \dots, x_m em uma das classes C_1 ou C_2 . A regra de decisão para a classificação é atribuir o ponto representado pelas entradas x_1, x_2, \dots, x_m à classe C_1 se a saída do perceptron for +1 e à classe C_2 se a saída do perceptron for -1 (em caso de função de ativação do tipo sinal).

Para o caso de duas variáveis de entrada, x_1 e x_2 , a fronteira de decisão entre as duas classes de saída do perceptron é uma reta. Um ponto (x_1, x_2) que se encontra acima da linha da fronteira é atribuído a classe C_1 e um ponto (x_1, x_2) que se encontra abaixo da linha da fronteira é atribuído a classe C_2 . Nota-se também que o efeito do bias b é meramente de deslocar a fronteira de decisão em relação à origem.

3.8.1.1 Algoritmo de Aprendizagem

Definiremos o vetor de entrada de tamanho $(m + 1)$ por 1, uma vez que adicionaremos o bias b ao vetor de pesos sinápticos \mathbf{w} .

$$\mathbf{x}(n) = [+1, x_1(n), x_2(n), \dots, x_m(n)]^T \quad (3.27)$$

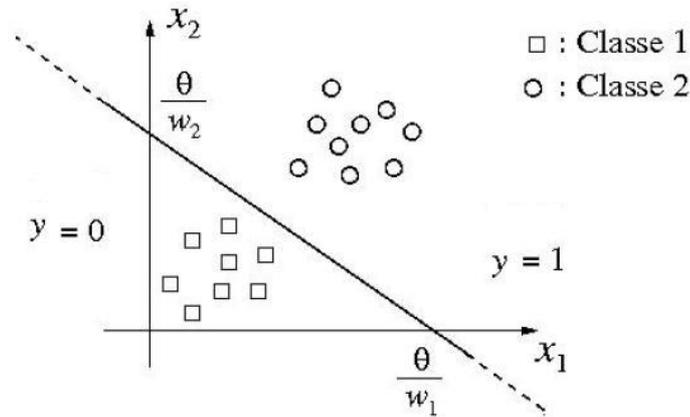


Figura 3.14: Linha de decisão para perceptron simples com duas variáveis de entrada (neste caso a função de ativação é do tipo degrau)

onde n representa o passo de iteração na aplicação do algoritmo. Teremos também um vetor de pesos sinápticos de tamanho $(m + 1)$ por 1, uma vez que adicionamos o bias b ao mesmo.

$$\mathbf{w}(n) = [b(n), w_1(n), w_2(n), \dots, w_m(n)]^T \quad (3.28)$$

A saída do combinador linear será

$$v(n) = \sum_{i=0}^m w_i(n) x_i(n) \quad (3.29)$$

$$v(n) = \mathbf{w}^T(n) \mathbf{x}(n) \quad (3.30)$$

onde $w_0(n)$ representa o bias $b(n)$.

Para o perceptron funcionar corretamente, as duas classes de saída devem ser linearmente separáveis, isto é, os padrões a serem classificados devem estar suficientemente separados entre si para assegurar que a superfície de decisão consista de um hiperplano.

Dado dois conjuntos de dados para treinar o classificador (perceptron), o processo de treinamento envolve o ajuste do vetor de peso \mathbf{w} de tal forma que as

duas classes C_1 e C_2 sejam linearmente separáveis, isto é, existe um vetor de peso \mathbf{w} para o qual podemos afirmar:

- $\mathbf{w}^T \mathbf{x} > 0$ para todo vetor de entrada \mathbf{x} pertencente à classe C_1 .
- $\mathbf{w}^T \mathbf{x} \leq 0$ para todo vetor de entrada \mathbf{x} pertencente à classe C_2 .

Consequentemente, o algoritmo para a modificação do vetor de pesos sinápticos é formulado como:

1. Se na n -ésima iteração, o vetor de entradas $\mathbf{x}(n)$ é corretamente classificado pelo vetor de pesos $\mathbf{w}(n)$, não há modificação no vetor de pesos do perceptron.

$$\mathbf{w}(n+1) = \mathbf{w}(n) \quad (3.31)$$

2. Caso contrário, o vetor de pesos do perceptron é atualizado de acordo com a regra:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \Delta \mathbf{w}(n) \quad (3.32)$$

onde $\Delta \mathbf{w}(n)$ vai depender do critério para treinamento da rede.

Para a formulação da regra de aprendizagem, introduziremos um sinal de erro, representado por $e(n)$, que será dado pela diferença entre o valor desejado $d(n)$ e o valor obtido $y(n)$, no instante de tempo n .

O sinal de erro $e(n)$ aciona um mecanismo de controle, cujo propósito é aplicar uma sequência de ajustes corretivos aos pesos sinápticos do neurônio. Os ajustes corretivos são projetados para aproximar passo a passo o sinal de saída $y(n)$ da resposta desejada $d(n)$. Este objetivo é alcançado minimizando-se uma função custo $\epsilon(n)$, definida em termos do sinal de erro $e(n)$ como:

$$\epsilon(n) = \frac{1}{2} e^2(n) \quad (3.33)$$

Os ajustes passo a passo dos pesos sinápticos ocorrerão até o sistema atingir um estado estável, quando o processo será encerrado.

Este processo de aprendizagem é denominado aprendizagem por correção de erro. Em particular, a minimização da função custo resulta na regra de aprendizagem normalmente referida como regra delta ou regra de Widrow-Holf, assim denominada em homenagem aos seus criadores (Widrow e Holf, 1960) [4]. A

regra delta é definida como:

$$\Delta w(n) = \eta e(n) x(n) \quad (3.34)$$

onde η é uma constante positiva independente do número da iteração n que determina a taxa de aprendizagem quando avançado em um passo no processo de aprendizagem e $e(n)$ é o vetor de sinal de erro. O η nada mais é que um fator de proporcionalidade para a variação dos pesos sinápticos.

Logo, caso haja um erro de classificação no perceptron simples, o novo vetor de pesos sinápticos será:

$$w(n+1) = w(n) + \eta e(n) x(n) \quad (3.35)$$

3.8.2 Perceptron Multicamadas (MLP, *multilayer perceptron*)

Tipicamente a rede consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada.

Utiliza como forma de treinamento um algoritmo de forma supervisionada, popularmente conhecido como algoritmo de retropropagação de erro (*error back-propagation*). Basicamente, este algoritmo consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação (*forward*), e um passo para trás, a retropropagação (*backward*). No passo para frente, um vetor de entrada é aplicado e seu efeito se propaga através da rede, camada por camada, produzindo uma saída como resposta real da rede. Durante esta fase, os pesos sinápticos são todos fixos. Durante o passo para trás, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro, para fazer com que a resposta real da rede se mova o mais próximo da resposta desejada, em um sentido estatístico.

A rede MLP possui três características principais que a diferenciam de uma rede perceptron simples:

- O modelo de cada neurônio da rede inclui uma função de ativação não-linear,

a qual deve possuir uma não-linearidade suave, sendo diferenciável. Exemplos de funções desse tipo são a função sigmóide logística e a função tangente hiperbólica.

- A rede contém uma ou mais camadas de neurônios ocultos, que não são parte da camada de entrada ou da camada de saída. Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo características mais significativas dos padrões de entrada.
- A rede exibe um alto grau de conectividade, determinado pelas sinapses da rede.

3.8.2.1 Algoritmo de Aprendizagem

A seguir, apresentaremos a notação utilizada para a dedução do algoritmo de aprendizagem:

- na iteração n , o n -ésimo padrão de treinamento é apresentado à rede.
- Temos um vetor de entrada x_1, x_2, \dots, x_m , que será aplicado à rede neural.
- $w_i(n)$ representa o vetor de pesos sinápticos conectando o vetor de entrada da rede ao i -ésimo neurônio da camada oculta, na iteração n . A correção aplicada a esse peso sináptico, caso necessite, será $\Delta w_i(n)$.

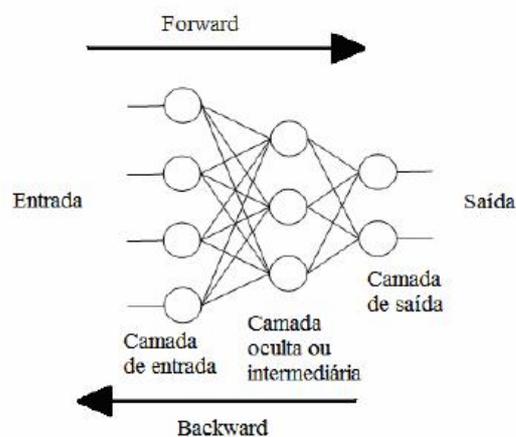


Figura 3.15: Rede MLP com uma camada oculta

- O bias do aplicado ao neurônio i da camada oculta é representado por b_i ; o

seu efeito é representado por uma sinapse de peso $w_{i0} = b_i$ conectada a uma entrada fixa igual a +1.

- O símbolo $u_i(n)$ será a soma ponderada de todas as entradas sinápticas acrescida do bias do neurônio i na iteração n ; constitui o sinal aplicado à função de ativação associada com o neurônio i .
- A função de ativação, que descreve a relação funcional de entrada-saída da não-linearidade associada ao neurônio i , é representada por $\varphi_i(\cdot)$.
- O símbolo $z_i(n)$ será a saída do neurônio i da camada oculta na iteração n ; constitui sinal de entrada da camada de saída.
- $m_{ji}(n)$ representa o peso sináptico conectando o vetor de saída do neurônio i da camada oculta da rede ao j -ésimo neurônio da camada de saída, na iteração n . A correção aplicada a esse peso sináptico, caso necessite, será $\Delta w_{ji}(n)$.
- O bias do aplicado ao neurônio j da camada de saída é representado por b_j ; o seu efeito é representado por uma sinapse de peso $m_{j0} = b_j$ conectada a uma entrada fixa igual a +1.
- O símbolo $a_j(n)$ será a soma ponderada de todas as entradas sinápticas da camada de saída acrescida do bias do neurônio j na iteração n ; constitui o sinal aplicado à função de ativação associada com o neurônio j .
- A função de ativação, que descreve a relação funcional de entrada-saída da não-linearidade associada ao neurônio j , é representada por $\varphi_j(\cdot)$.
- O símbolo $o_j(n)$ será a saída do neurônio j da camada de saída na iteração n ; constitui a saída da rede neural.
- $d_j(n)$ se refere à resposta desejada para o neurônio j , na iteração n .
- $e_j(n)$ se refere ao sinal de erro na saída do neurônio j , na iteração n .
- $\varepsilon(n)$ é soma instantânea dos erros quadráticos na iteração n .
- Temos um total de q neurônios na camada de saída.

Logo teremos:

- Para o i -ésimo neurônio da camada oculta:

$$u_i(n) = \sum_{i=0}^m w_i(n) x_i(n) \quad (3.36)$$

e

$$z_i(n) = \varphi(u_i(n)) \quad (3.37)$$

- Para o j-ésimo neurônio da camada de saída:

$$a_j(n) = \sum_{i=0}^q m_{ji}(n) z_i(n) \quad (3.38)$$

e

$$o_j(n) = \varphi(a_j(n)) \quad (3.39)$$

O sinal de erro na saída do neurônio j, na iteração n, é definido por:

$$e_j(n) = d_j(n) - o_j(n) \quad (3.40)$$

onde j é um neurônio de saída.

Correspondentemente, a soma instantânea dos erros quadráticos no instante n, $\epsilon(n)$, será:

$$\epsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.41)$$

onde C inclui todos os neurônios da camada de saída da rede e a divisão por $\frac{1}{2}$ se justifica para facilitar os cálculos.

Logo, o erro quadrático médio (EQM) é definido por:

$$\epsilon_{med} = \frac{1}{N} \sum_{n=1}^N \epsilon(n) \quad (3.42)$$

O objetivo do sistema é encontrar um conjunto de pesos sinápticos que minimize o erro médio quadrático. Sabendo que o erro médio quadrático e, conseqüentemente, o erro quadrático instantâneo são funções quadráticas e são dependentes do vetor de pesos sinápticos, e também sabendo que o gradiente de uma função é um vetor tangencial a superfície da função e tem sentido na direção de crescimento da mesma, utilizaremos o negativo do gradiente da função de erro quadrático instantâneo para tentarmos encontrar os pesos sinápticos que a minimizam. Logo, para a camada de saída, teremos que:

$$m_{ji}(n+1) = m_{ji}(n) - \eta \frac{\partial \epsilon(n)}{\partial m_{ji}(n)} \quad (3.43)$$

Utilizando a regra da cadeia, teremos:

$$\frac{\partial \epsilon(n)}{\partial m_{ji}(n)} = \frac{\partial \epsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial o_j(n)} \frac{\partial o_j(n)}{\partial a_j(n)} \frac{\partial a_j(n)}{\partial m_{ji}(n)} \quad (3.44)$$

A seguir, temos o cálculo das derivadas de (3.44):

$$\frac{\partial \epsilon(n)}{\partial e_j(n)} = e_j(n) \quad (3.45)$$

$$\frac{\partial e_j(n)}{\partial o_j(n)} = \frac{\partial (d_j(n) - o_j(n))}{\partial o_j(n)} = -1 \quad (3.46)$$

$$\frac{\partial o_j(n)}{\partial a_j(n)} = \varphi'(a_j(n)) \quad (3.47)$$

$$\frac{\partial a_j(n)}{\partial m_{ji}(n)} = z_i(n) \quad (3.48)$$

Conseqüentemente:

$$m_{ji}(n+1) = m_{ji}(n) - \eta e_j(n) (-1) \varphi'(a_j(n)) z_i(n) \quad (3.49)$$

$$m_{ji}(n+1) = m_{ji}(n) + \eta e_j(n) \varphi'(a_j(n)) z_i(n) \quad (3.50)$$

que é a regra de aprendizagem para a camada de saída da rede MLP.

Quando o neurônio está localizado em uma camada oculta da rede, não existe uma resposta desejada especificada para aquele neurônio. Correspondentemente, o sinal de erro para um neurônio oculto deve ser

determinado recursivamente, em termos dos sinais de erro de todos os neurônios aos quais o neurônio oculto está diretamente conectado. O segredo está em calcular o gradiente da função erro quadrático pelo vetor de pesos sinápticos da camada de entrada para ajuste da seguinte equação:

$$\mathbf{w}_i(n+1) = \mathbf{w}_i(n) - \eta \frac{\partial \epsilon(n)}{\partial \mathbf{w}_i(n)} \quad (3.51)$$

Utilizando a regra da cadeia, temos

$$\frac{\partial \epsilon(n)}{\partial \mathbf{w}_i(n)} = \frac{\partial \epsilon(n)}{\partial a_j(n)} \frac{\partial a_j(n)}{\partial z_i(n)} \frac{\partial z_i(n)}{\partial u_i(n)} \frac{\partial u_i(n)}{\partial \mathbf{w}_i(n)} \quad (3.52)$$

A seguir, temos o cálculo das derivadas de (3.52):

$$\frac{\partial \epsilon(n)}{\partial a_j(n)} = \sum_q e_j(n) \frac{\partial e_j(n)}{\partial a_j(n)} = \sum_q e_j(n) \frac{\partial (d_j(n) - \varphi(a_j(n)))}{\partial a_j(n)} = -\varphi'(a_j(n)) \sum_q e_j(n) \quad (3.53)$$

$$\frac{\partial a_j(n)}{\partial z_i(n)} = m_{ji}(n) \quad (3.54)$$

$$\frac{\partial z_i(n)}{\partial u_i(n)} = \varphi'(u_i(n)) \quad (3.55)$$

$$\frac{\partial u_i(n)}{\partial \mathbf{w}_i(n)} = \mathbf{x}(n) \quad (3.56)$$

Logo:

$$\mathbf{w}_i(n+1) = \mathbf{w}_i(n) + \eta e_i(n) \varphi'(u_i(n)) \mathbf{x}(n) \quad (3.57)$$

onde

$$e_i(n) = \sum_{j=1}^q e_j(n) \varphi'(a_j(n)) m_{ji}(n) \quad (3.58)$$

3.9 Conclusão

Neste capítulo, foram apresentados os aspectos gerais sobre redes neurais artificiais, como modelo de um neurônio, funções de ativação, modos de aprendizagem, entre outros, necessários para o desenvolvimento do presente trabalho. A partir deste ponto, detalharemos o desenvolvimento do trabalho realizado.

4 PREDIÇÃO DO SINAL ATRAVÉS DE REDES NEURAIS

4.1 Introdução

Devido a complexidade e grande variabilidade encontrada em ambientes *indoor*, a predição da potência do sinal neste tipo de ambiente é um campo de estudo ainda em aberto, não havendo um modo completamente eficaz para sua realização. Neste trabalho, foram projetadas duas redes neurais, uma do tipo perceptron simples e a outra do tipo MLP, para a realização deste tipo de predição em um ambiente residencial de um único pavimento. Para validação dos resultados obtidos pelas redes neurais, foram projetados também três modelos semi-empíricos existentes na literatura: um modelo do espaço livre adaptado, um modelo por atenuação linear e um modelo COST 231 Keenan e Motley.

O projeto da rede neural perceptron simples foi realizado por caráter acadêmico, mas, desde o início, não se esperava resultados consistentes da mesma. Isso ocorreu pelo fato de, estudando os modelos semi-empíricos existentes na literatura, saber-se que a propagação dos sinais ocorre de maneira não linear e a rede neural perceptron simples ser uma estrutura linear, não havendo adaptabilidade neste caso.

O modelo do espaço livre é o modelo de propagação mais simples existente e sua aplicação ocorre, em geral, para sinais *outdoor*. Visto que neste trabalho visávamos uma predição de sinais *indoor*, foi utilizado um modelo do espaço livre adaptado, visando uma melhor adequação do modelo ao ambiente alvo.

A justificativa da escolha dos modelos semi-empíricos citados acima para validação segue abaixo:

- Espaço livre adaptado – modelo mais simples de propagação, mas que em geral representa bem as principais características do sistema. Servirá apenas

de uma base superficial do comportamento do sistema.

- Atenuação linear – modelo semelhante ao modelo do espaço livre adaptado, diferenciando-se pela presença de um fator de perda linear pela distância, fazendo com que obtenha resultados melhor condizentes com a realidade com baixo custo computacional.
- COST 231 Keenan e Motley – modelo complexo que necessita de um vasto conjunto de parâmetros para sua utilização, sendo o mais completo quando tratamos da predição do sinal em um único pavimento, como é o nosso caso.

Medidas de propagação no ambiente em questão foram realizadas para obtenção de dados para o treinamento da rede neural e ajuste de parâmetros dos modelos semi-empíricos.

Nas próximas seções deste capítulo veremos a descrição completa do trabalho realizado.

4.2 Equipamentos Utilizados para Medidas de Propagação

1. *Wireless Router*

- Modelo: D-Link, DI – 524 .
- Potência de transmissão: 2dB.
- Ganho da antena transmissora: 0 dBi.
- Frequência: 2.4 GHz.
- *Throughput* máximo: 54 Mbps.

2. *Client Adapter*

- Modelo: Atheros, AR5007EG.
- Ganho da antena receptora: 0 dBi.
- Frequência: 2.4 GHz.
- *Throughput* máximo: 54 Mbps.

3. *Softwares* de medição

- Network Stumbler 0.4.0 desenvolvido pela NetStumbler.
- Advanced Wifi-Manager 3.8 desenvolvido pela Nicomsoft.

4. Notebook

- Compaq Presario C750BR Notebook PC.

4.3 Medidas de Propagação

Nesta etapa do trabalho, o *wireless router* foi posicionado de modo a cobrir os diversos cômodos do ambiente e a campanha de medidas da potência do sinal pelo ambiente foi iniciada.

O ambiente no qual foram realizadas as medidas foi descrito através de coordenadas cartesianas, obtendo assim um espaço totalmente coberto por coordenadas nas direção **x**, **y** e **z**, sendo a origem do eixo de coordenadas posicionada na posição do *wireless router*.

Para cada medida realizada, foram obtidos os seguintes parâmetros:

- Distância do ponto de medida até a origem na direção **x**, em centímetros.
- Distância do ponto de medida até a origem na direção **y**, em centímetros.
- Distância do ponto de medida até a origem na direção **z**, em centímetros.
- Presença ou não de LoS do ponto em questão para o *wireless router*, tendo o valor 1 para o caso de presença de LoS e valor 0 para o caso de ausência.
- Quantidade de obstáculos entre o ponto em questão e o *wireless router* compostos em sua maior parte por madeira.
- Quantidade de obstáculos entre o ponto em questão e o *wireless router* compostos em sua maior parte por parede convencional (concreto).
- Seis medidas da potência do sinal na posição de medida, sendo três obtidas pelo *software* Network Stumbler e três obtidas pelo *software* Advanced Wifi-Manager, todas em dB.

Na figura 4.1, observamos o valor de potência obtido em cada ponto através da média aritmética das seis medidas realizadas nesses pontos. Estes valores foram os valores alvos (parâmetros de saída) para os diversos modelos com os quais trabalhamos.

4.4 Modelos Projetados

Nesta seção, explicaremos como foram projetados cada um dos modelos utilizados neste trabalho, iniciando pelos três modelos semi-empíricos e terminando pelas duas redes neurais (perceptron simples e MLP).

4.4.1 Modelo do Espaço Livre Adaptado

Como dito anteriormente, apesar de o modelo do espaço livre descrever bem, mesmo de modo simples, o comportamento do sistema, ele, em geral, se aplica em ambientes *outdoors*, ou seja, em sistemas menos complexos do que ambientes *indoor*. Logo, sua aplicação neste trabalho não era a mais adequada.

Em razão do que foi explicado no parágrafo anterior, foi utilizada uma versão adaptada do modelo do espaço livre, permitindo uma maior flexibilidade do mesmo aos ambientes *indoor*. Esta adaptabilidade foi obtida fazendo com que o coeficiente de perda de percurso tivesse um peso em várias variáveis do sistema e calculando-se o seu valor que minimizasse o erro quadrático médio.

A seguir, deduziremos a expressão utilizada neste modelo. A atenuação do sinal será (semelhante ao modelo do espaço livre, diferenciando pelo coeficiente de perda de percurso):

$$L_{total}(dB) = 10 \log\left(\frac{P_T}{P_R}\right) = -10 \log\left(\frac{G_T G_R \lambda^n}{(4\pi d)^n}\right) \quad (4.1)$$

onde n é o coeficiente de perda de percurso a ser calculado de acordo com a minimização do erro quadrático médio. Como foram utilizadas antenas com ganho de 0 dBi, temos:

$$L_{total}(dB) = -10 \cdot n \cdot \log\left(\frac{c/f}{4\pi d}\right) = -10 \cdot n \cdot \log\frac{(3 \cdot 10^8)}{4\pi d * f * 10^6} \quad (4.2)$$

$$L_{total}(dB) = -13.78 \cdot n + 10 \cdot n \cdot \log(d) + 10 \cdot n \cdot \log(f) \quad (4.3)$$

Conseqüentemente, como a potência de transmissão é de 2 dB, teremos que a potência recebida, em dB, será:

$$P_R = P_T + 13.78.n - 10.n.\log(d) - 10.n.\log(f) \quad (4.4)$$

$$P_R = 2 + 13.78.n - 10.n.\log(d) - 10.n.\log(f) \quad (4.5)$$

onde f é a frequência em MHz e d é a distância em metros.

4.4.2 Modelo por Atenuação Linear

Modelo bastante simples, similar ao modelo do espaço livre adaptado. Diferencia-se do modelo anterior pela adição de um coeficiente de atenuação linear multiplicativo com a distância. A expressão para a potência recebida, em dB, será:

$$P_R = 2 + 13.78.n - 10.n.\log(d) - 10.n.\log(f) - \alpha d \quad (4.6)$$

onde α é o coeficiente de atenuação em dB por metro, f é a frequência em MHz e d é a distância em metros.

O valor do coeficiente de atenuação foi obtido pela interpolação de valores de coeficientes de atenuação mostrados na tabela 2.2. O valor adotado neste modelo foi $\alpha=0.55$ dB/m.

4.4.3 Modelo COST 231 Keenan e Motley

Foi projetado devido a ser um dos modelos mais completos para ambientes *indoor*. Este modelo já foi detalhado na seção 2.3.5.

Para a sua utilização, são necessárias mais informações quando comparamos aos modelos anteriormente projetados. A seguir temos os valores obtidos após a etapa de medidas de propagação para os parâmetros necessários:

- perda de propagação a um metro da antena transmissora – 32 dB
- perda de propagação do sinal através de obstáculos de madeira – 3.25 dB
- perda de propagação do sinal através de obstáculos de concreto – 7 dB

Os parâmetros da quantidade de obstáculos existente de madeira ou concreto entre o transmissor e o receptor para cada ponto são fornecidos ao

sistema na etapa de treinamento e, posteriormente, na etapa de teste.

Consequentemente, obtivemos a seguinte expressão para este modelo para a potência recebida (em dB):

$$P_R = P_T - 32 - 10 \log(d) - K_m \cdot 3.25 - K_c \cdot 7 \quad (4.7)$$

$$P_R = 2 - 32 - 10 \log(d) - K_m \cdot 3.25 - K_c \cdot 7 \quad (4.8)$$

$$P_R = -30 - 10 \log(d) - K_m \cdot 3.25 - K_c \cdot 7 \quad (4.9)$$

onde:

- K_m – número de obstáculos de madeira entre o transmissor e o receptor para o respectivo ponto.
- K_c – número de obstáculos de concreto entre o transmissor e o receptor para o respectivo ponto.

4.4.4 Rede Neural Perceptron Simples

A primeira rede neural projetada foi uma rede do tipo perceptron simples com aprendizagem supervisionada, utilizando um único neurônio, como uma função de ativação linear multiplicativa unitária, ou seja, a saída da rede consistia basicamente da multiplicação dos dados de entrada pelo vetor de pesos sinápticos. A taxa de aprendizagem foi $\eta = 0.03$. Os parâmetros de entrada utilizados foram:

- Distância do ponto de medida até a origem na direção x , em centímetros.
- Distância do ponto de medida até a origem na direção y , em centímetros.
- Presença ou não de LoS do ponto em questão para o *wireless router*, tendo o valor 1 para o caso de presença de LoS e valor 0 para o caso de ausência.
- Quantidade de obstáculos entre o ponto em questão e o *wireless router* compostos em sua maior parte por madeira.
- Quantidade de obstáculos entre o ponto em questão e o *wireless router* compostos em sua maior parte por parede convencional (concreto).

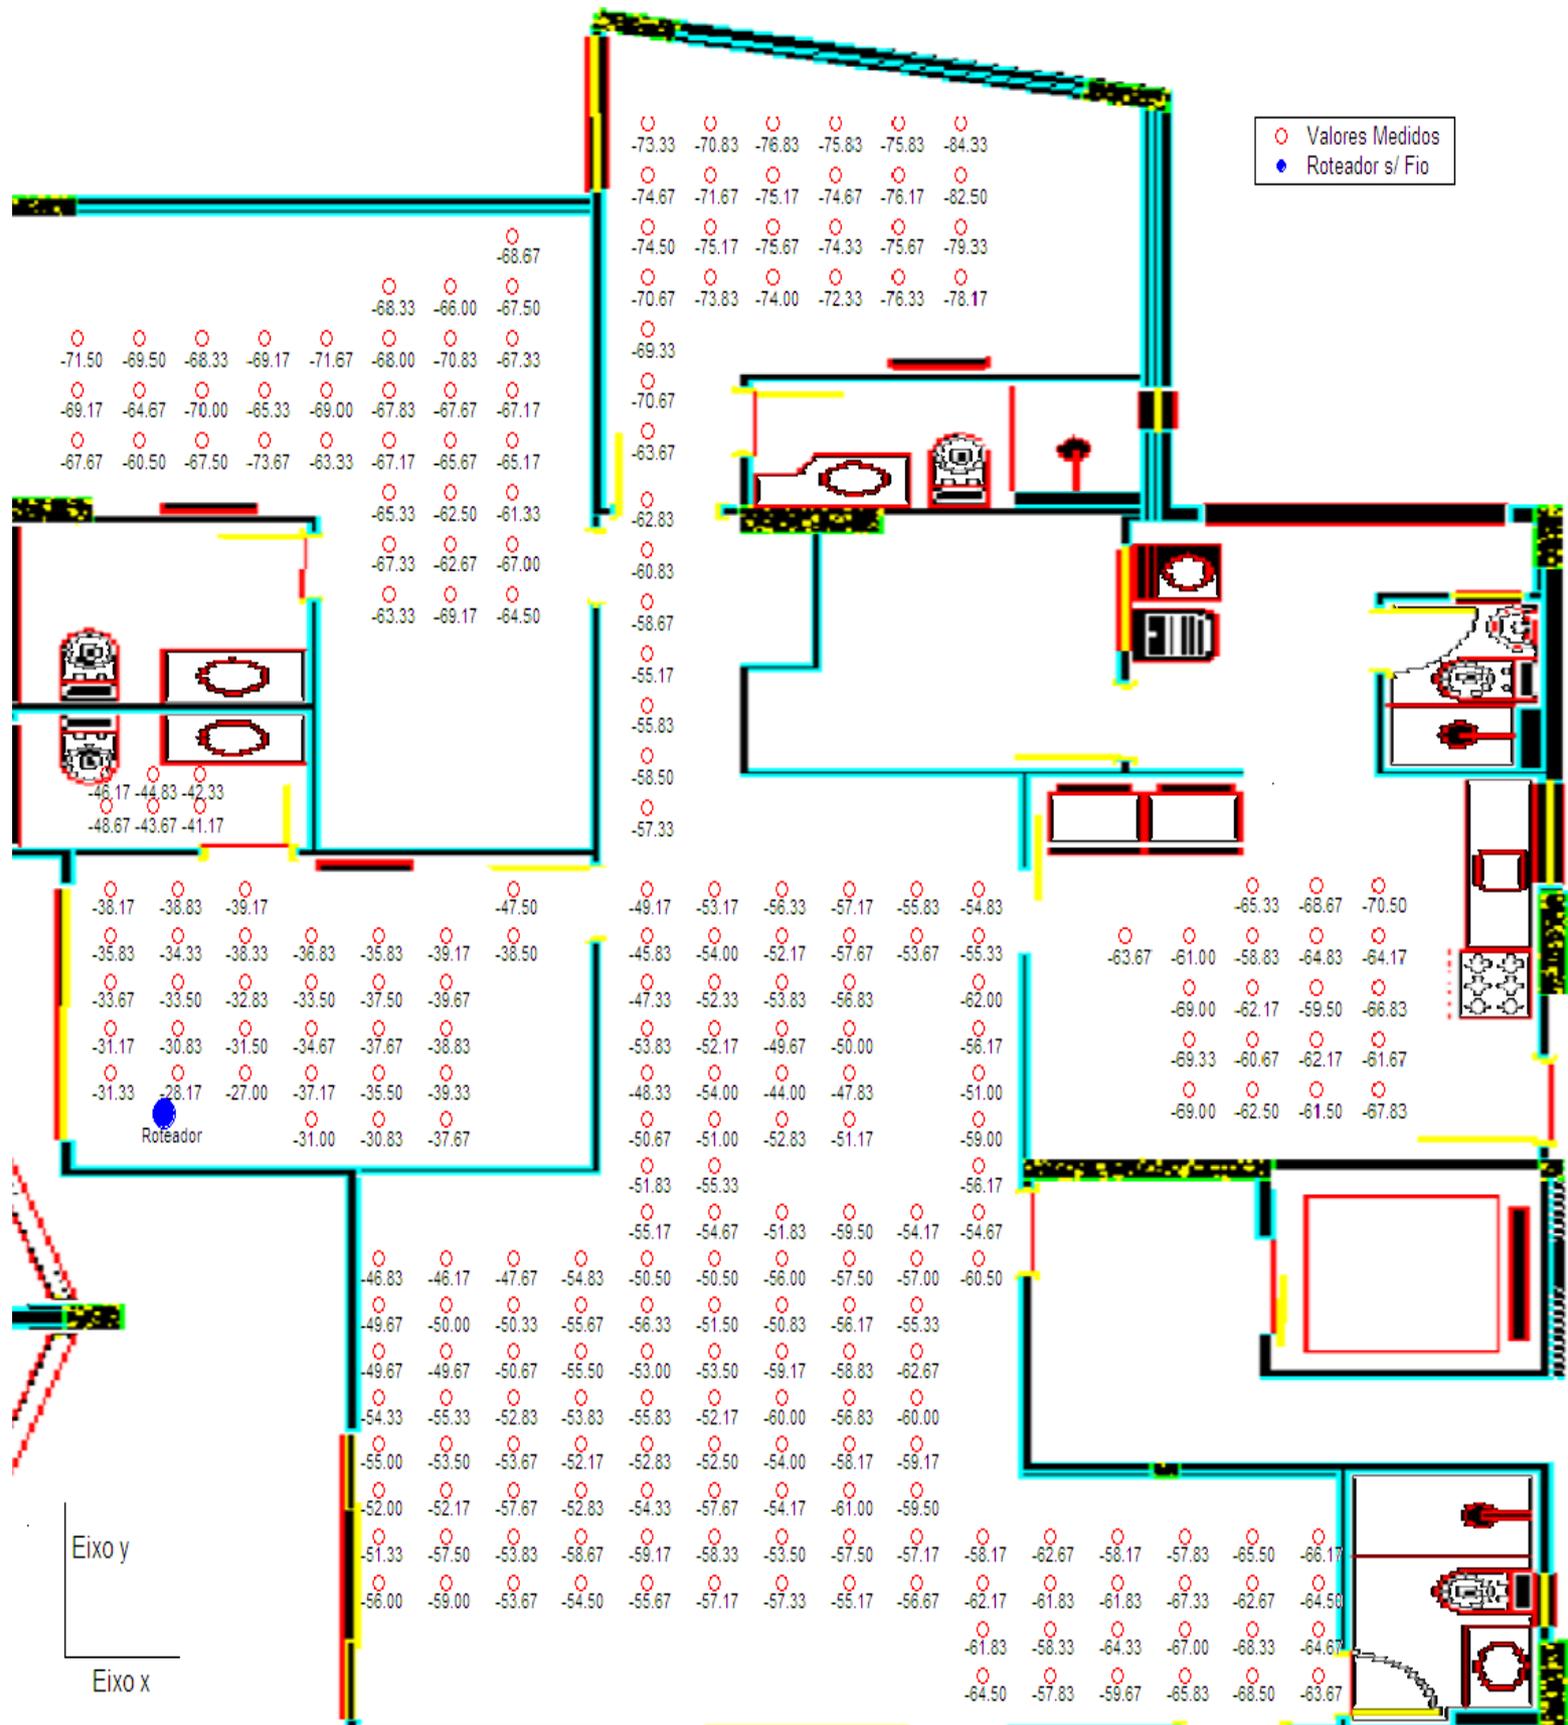


Figura 4.1: Amostras de propagação obtidas mostradas em um plano x por y

4.4.5 Rede Neural Perceptron Multicamadas

A segunda e última rede neural projetada foi uma rede neural perceptron multicamadas com aprendizagem supervisionada, com uma camada oculta e uma camada de saída, utilizando o algoritmo *backpropagation*. A camada oculta foi composta por 7 neurônios não-lineares, com funções de ativação do tipo tangente hiperbólica. A camada de saída foi composta por um só neurônio, também utilizando uma função de ativação não linear do tipo tangente hiperbólica, mas sua saída era multiplicada por 100, visto que a saída da função tangente hiperbólica é limitada entre -1 e 1. Logo, a saída da rede neural projetada está limitada entre os valores -100 e 100. Caso necessite-se de um intervalo maior, basta modificar esse fator multiplicativo. A taxa de aprendizagem utilizada foi $\eta = 0.03$. Os parâmetros de entrada utilizados foram os mesmos utilizados pelo modelo rede neural perceptron simples (modelo 4.4.4).

A definição do número de neurônios da camada oculta ocorreu através de simulações realizadas visando um baixo erro quadrático médio na saída. Através destas simulações, foi visto que com o número de neurônios utilizados, mesmo com um número relativamente baixo de épocas de treinamento, a rede já alcançaria um valor baixo de erro. Na figura 4.2 observa-se alguns dos resultados obtidos através destas simulações, onde vemos o erro quadrático médio obtido para diversos números de neurônios da camada oculta.

4.5 Simulação

Para as simulações dos modelos, as seguintes considerações foram feitas:

- Como a quantidade de amostras obtidas por cômodo não são iguais, foi definido um número mínimo de amostras por cômodo a ser utilizado por qualquer um dos modelos durante o seu treinamento, definido como duas amostras.
- Quando definiu-se a porcentagem de amostras utilizadas para treinamento, esses dados foram proporcionais por cômodo do ambiente. Por exemplo: se

90% das amostras totais foram definidas para treinamento, aproximadamente 90% das amostras de cada cômodo foi utilizada para o treinamento do modelo.

Para a comparação entre os modelos, foram considerados os seguintes critérios (tanto para a fase de treino quanto para a fase de teste dos modelos):

- Erro absoluto médio – erro absoluto médio obtido para as amostras utilizadas.
- Erro quadrático médio – erro quadrático médio obtido para as amostras utilizadas.
- Taxa de acertos – para cada modelo, o erro obtido para cada amostra é comparado com um limiar definido (que para todas as simulações realizadas foi de 3 dB). Se o valor do erro for menor que o limiar, é considerado que o modelo realizou uma predição correta da potência do sinal e, caso contrário, é considerado que o modelo não realizou uma predição correta. Através desses dados, calcula-se uma taxa de acertos tanto para a fase de treino quanto para a fase de testes de acordo com o número de amostras utilizadas.

Ao todo, foram realizadas três simulações gerais. Em cada simulação geral, cada um dos modelos foi simulado 1000 vezes, para se obter uma estimativa média dos resultados do mesmo. Em cada uma dessas simulações, as amostras para a fase de treinamento e para a fase de teste foram definidas aleatoriamente. A seguir, veremos a quantidade de amostras utilizadas para treinamento e teste em cada uma das simulações gerais:

- Na primeira simulação geral, cada modelo utilizou aproximadamente 90% das amostras (240) para treinamento e 10% (27) para teste. Nesta simulação geral, cada simulação da rede neural perceptron simples foi treinada com 1000 épocas e cada simulação da rede neural perceptron multicamadas foi treinada com 250 épocas.
- Na segunda simulação geral, cada modelo utilizou aproximadamente 50% das amostras (131) para treinamento e 50% (136) para teste. Nesta simulação geral, cada simulação da rede neural perceptron simples foi treinada com 1000 épocas e cada simulação da rede neural perceptron multicamadas foi treinada com 550 épocas.
- Na terceira simulação geral, cada modelo utilizou aproximadamente 10% das

amostras (29) para treinamento e 90% (238) para teste. Nesta simulação geral, cada simulação da rede neural perceptron simples foi treinada com 1000 épocas e cada simulação da rede neural perceptron multicamadas foi treinada com 2200 épocas.

A realização de três simulações gerais ocorreu para comparação dos resultados de cada modelo perante quantidades diferentes de amostras para a fase de treinamento e para a fase de teste.

4.6 Resultados Obtidos

A seguir, vemos os resultados obtidos em cada uma das simulações gerais. Nas tabelas dos resultados obtidos em cada uma das simulações gerais, temos:

- Coef. Perda – coeficiente de perda de percurso.
- EAM (dB) – erro absoluto médio em dB.
- EQM (dB) – erro quadrático médio em dB.
- TDA – taxa de acertos.

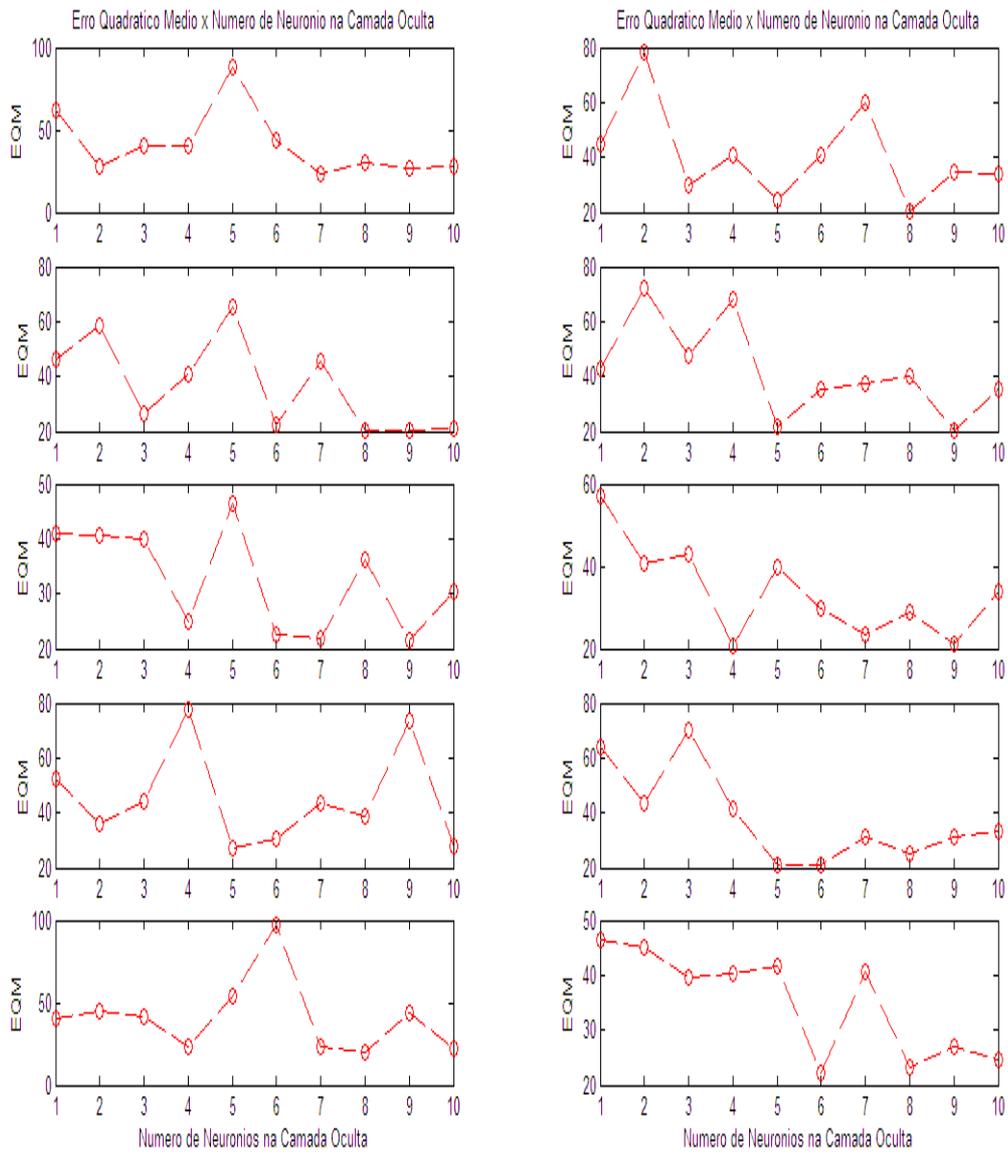


Figura 4.2: 10 gráficos do erro quadrático médio versus o número de neurônios na camada oculta

4.6.1 Primeira Simulação Geral

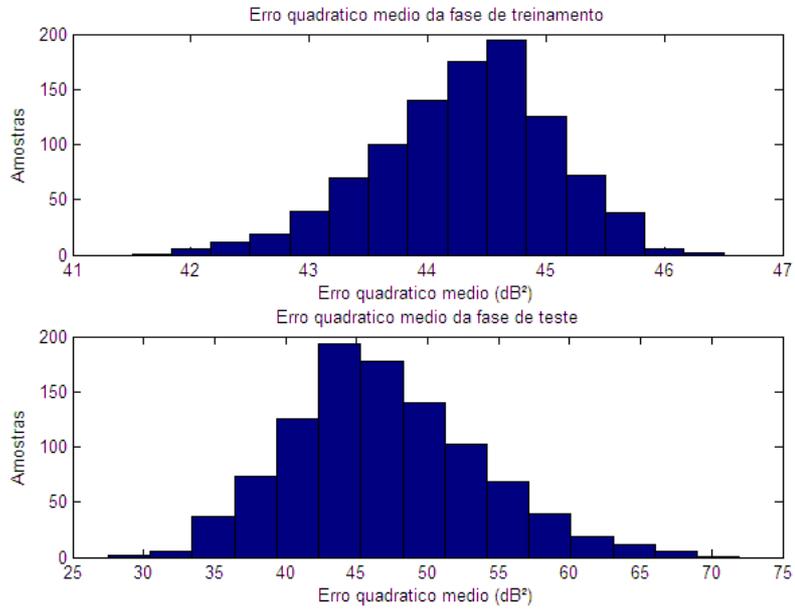


Figura 4.3: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado

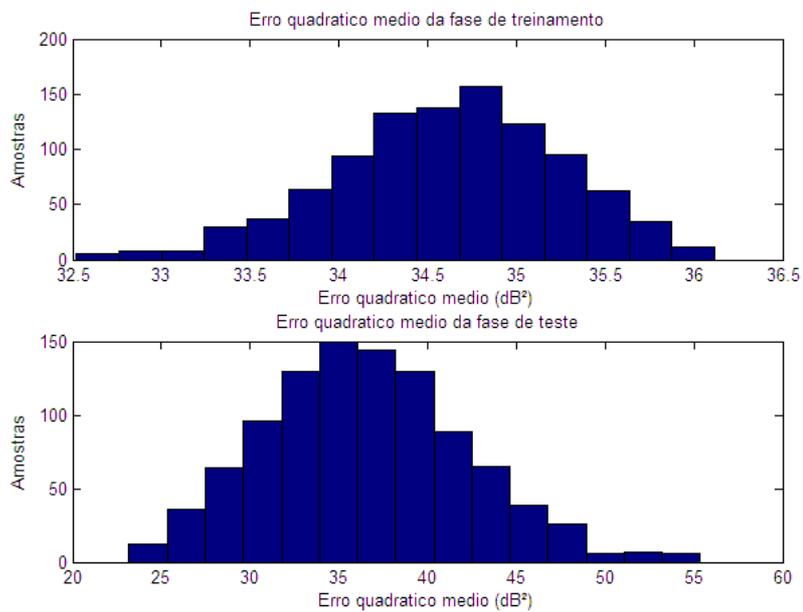


Figura 4.4: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear

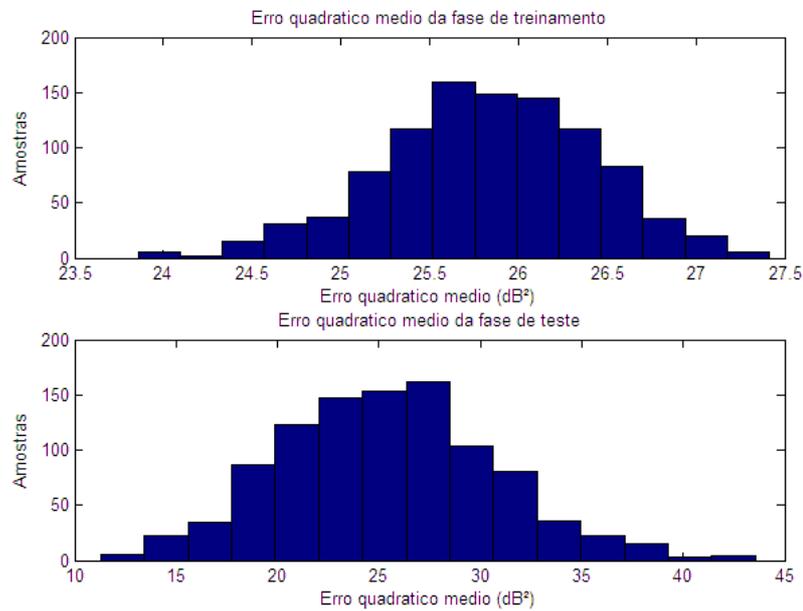


Figura 4.5: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley

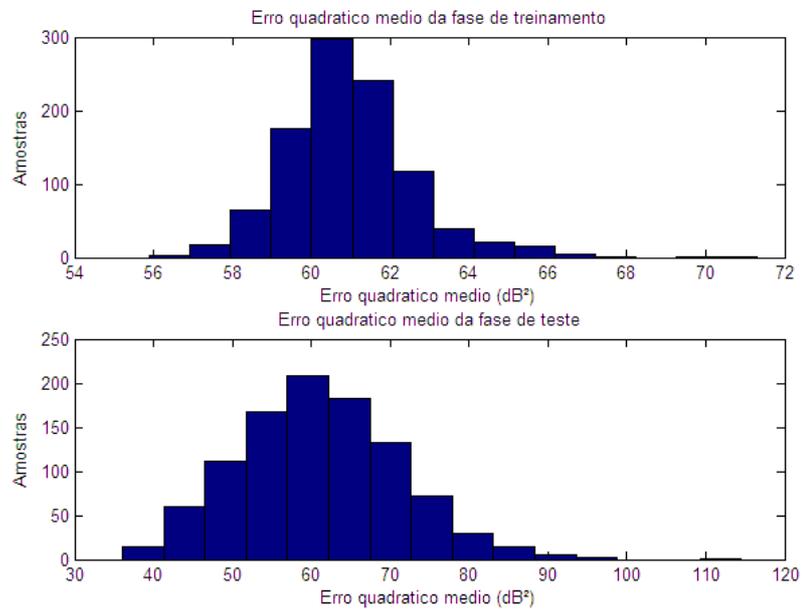


Figura 4.6: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Simples

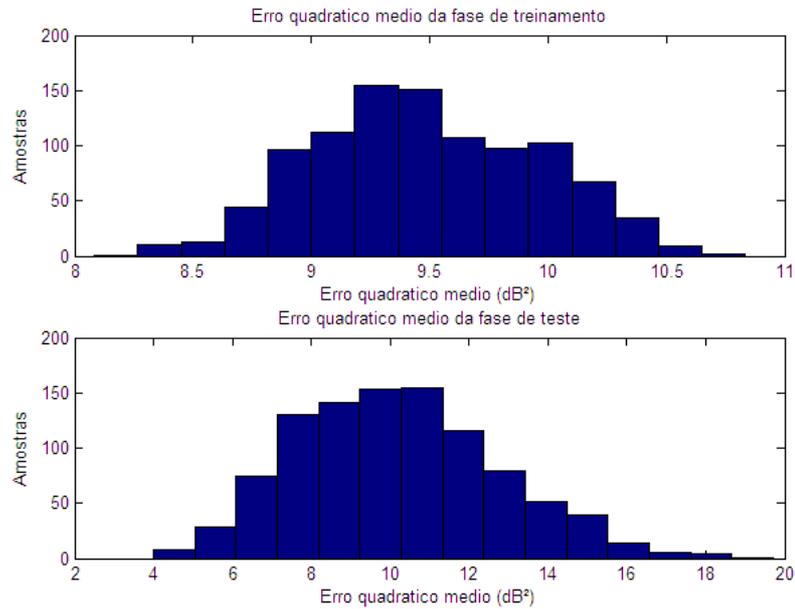


Figura 4.7: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da Rede Neural Perceptron Multicamadas

Modelo			Espaço Livre Adaptado	Atenuação Linear	COST 231/Keenan e Motley	PS	MLP
Treino (240)	Coef. Perda	Média	2.22	2.11	1.73	-	-
		D. Padrão	0.00	0.00	0.01	-	-
	EAM (dB)	Média	5.26	4.67	4.11	6.48	2.47
		D. Padrão	0.05	0.05	0.05	0.16	0.08
	EQM (dB ²)	Média	44.31	34.61	25.83	60.99	9.48
		D. Padrão	0.75	0.64	0.59	1.63	0.47
TDA (%)	Média	36.42	41.31	42.46	25.00	67.48	
	D. Padrão	0.83	0.80	1.14	4.15	1.85	
Teste (27)	EAM (dB)	Média	5.46	4.84	4.07	6.48	2.56
		D. Padrão	0.43	0.42	0.47	0.63	0.34
	EQM (dB ²)	Média	47.01	36.52	25.44	61.02	10.20
		D. Padrão	6.72	5.71	5.26	10.12	2.57
	TDA (%)	Média	34.77	39.68	42.81	24.57	66.16
		D. Padrão	7.03	7.13	8.54	8.34	8.81

Tabela 4.1: Estatísticas dos modelos obtidas para a primeira simulação geral

4.6.2 Segunda Simulação Geral

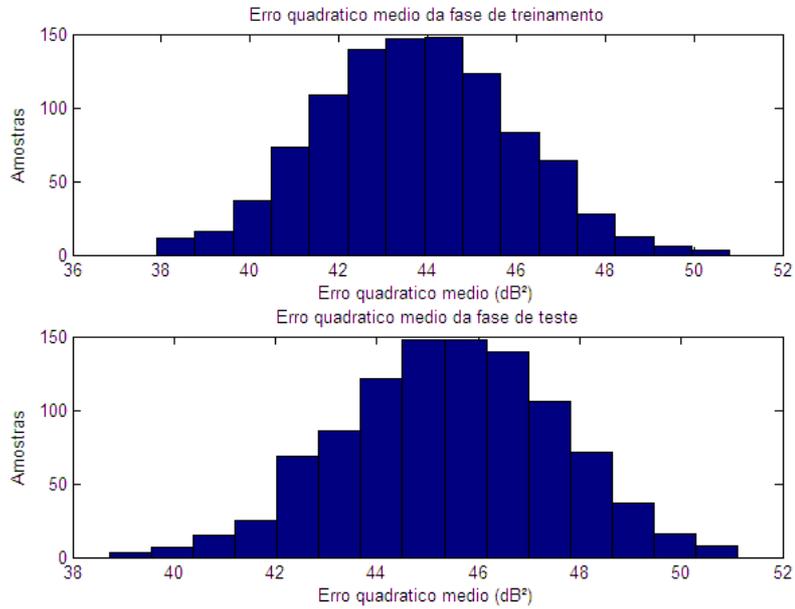


Figura 4.8: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado

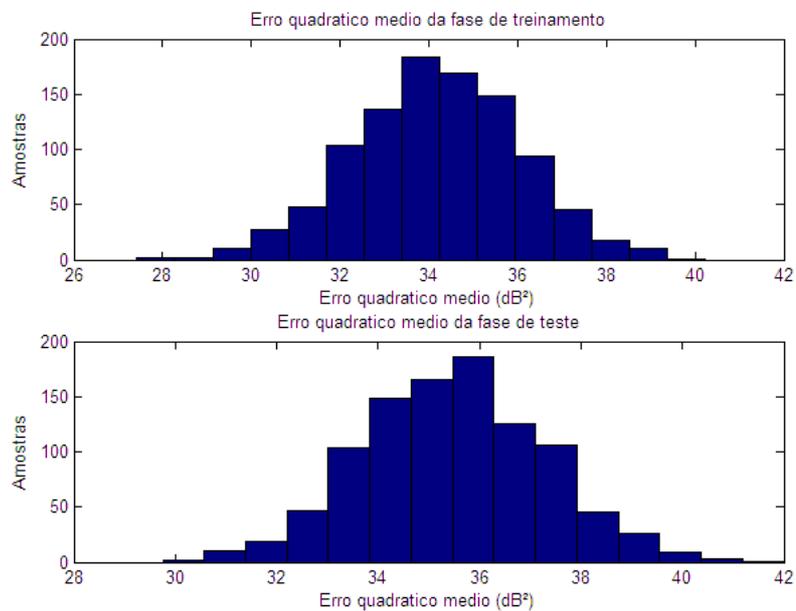


Figura 4.9: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear

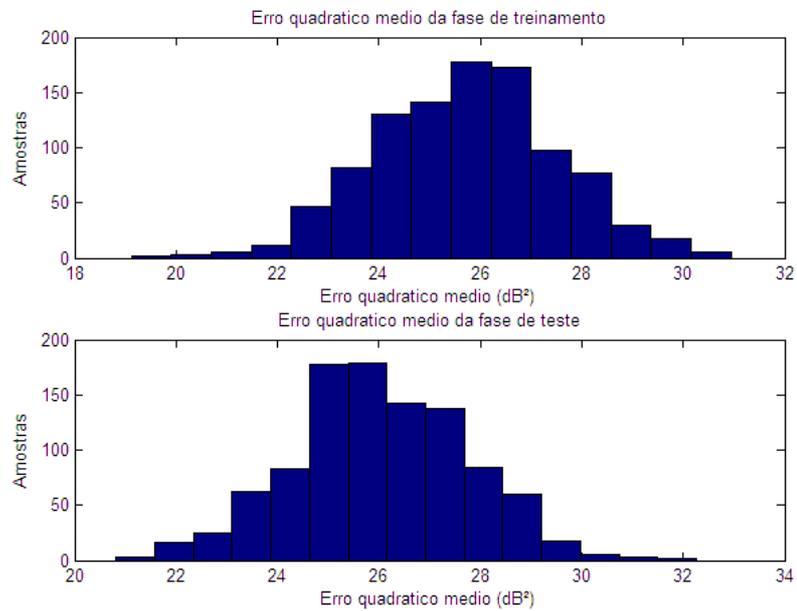


Figura 4.10: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley

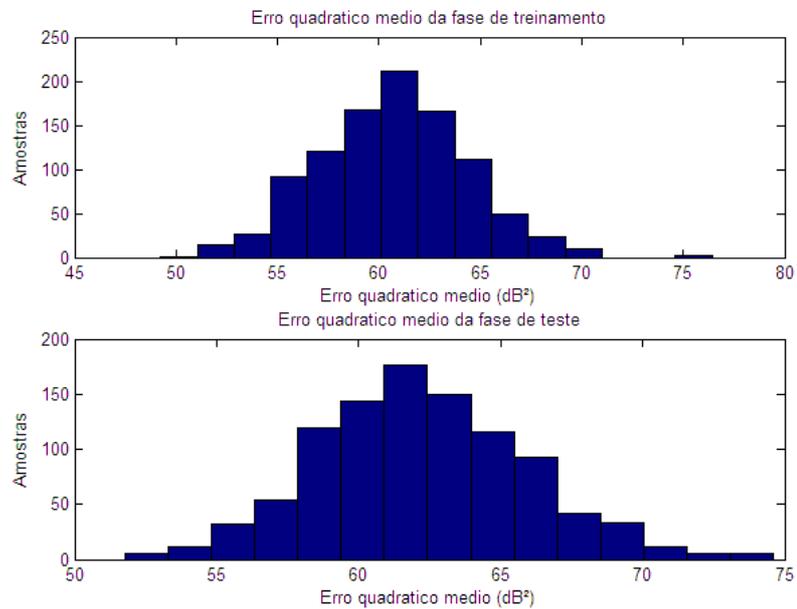


Figura 4.11: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da rede Neural Perceptron Simples

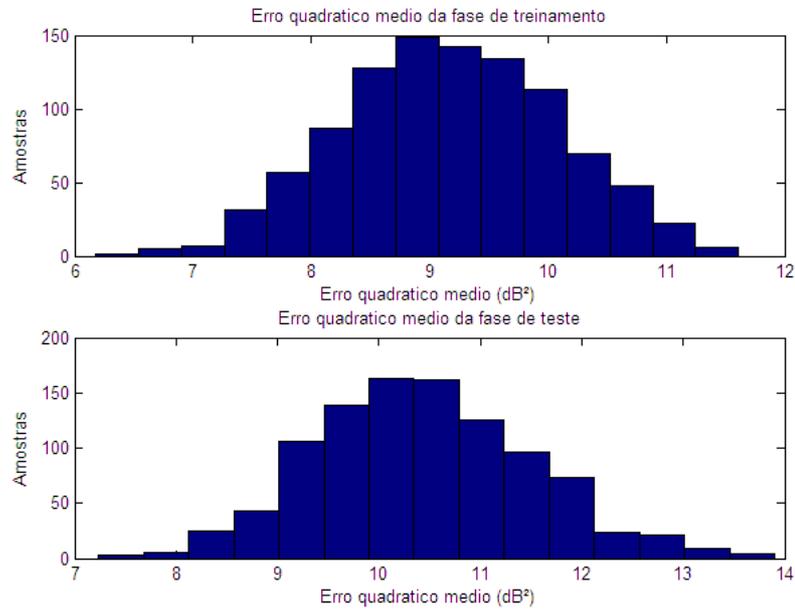


Figura 4.12: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da rede Neural Perceptron Multicamadas

Modelo			Espaço Livre Adaptado	Atenuação Linear	COST 231/Keenan e Motley	PS	MLP
Treino (131)	Coef. Perda	Média	2.22	2.10	1.72	-	-
		D. Padrão	0.01	0.01	0.04	-	-
	EAM (dB)	Média	5.23	4.64	4.11	6.48	2.42
		D. Padrão	0.15	0.14	0.16	0.25	0.13
	EQM (dB ²)	Média	43.76	34.18	25.71	60.73	9.17
		D. Padrão	2.19	1.86	1.79	3.67	0.91
	TDA (%)	Média	36.88	41.95	41.62	25.02	68.44
D. Padrão		2.51	2.57	3.31	4.71	3.51	
Teste (136)	EAM (dB)	Média	5.32	4.73	4.13	6.57	2.59
		D. Padrão	0.14	0.13	0.16	0.25	0.15
	EQM (dB ²)	Média	45.45	35.48	26.03	62.27	10.44
		D. Padrão	2.11	1.80	1.73	3.71	1.07
	TDA (%)	Média	36.33	41.55	41.85	24.18	65.01
		D. Padrão	2.78	2.87	3.24	4.20	3.63

Tabela 4.2: Estatísticas dos modelos obtidas para a segunda simulação geral

4.6.3 Terceira Simulação Geral

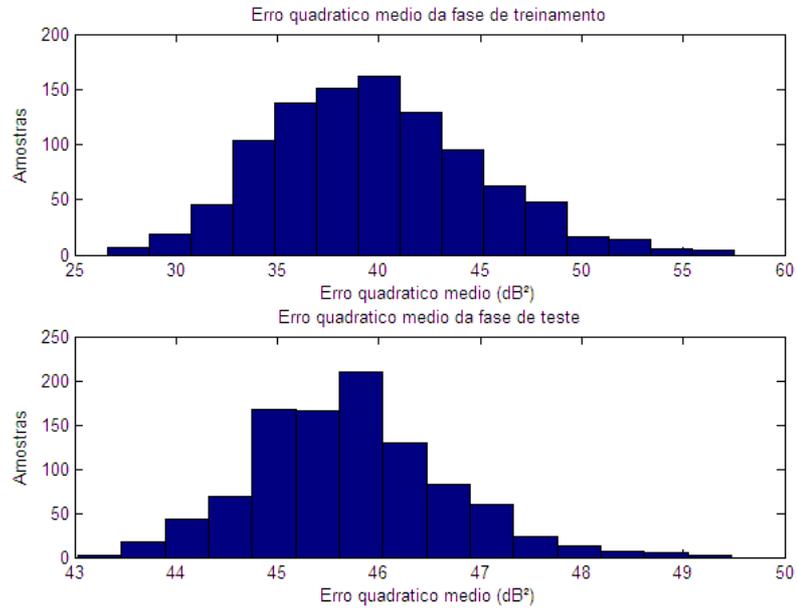


Figura 4.13: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo do Espaço Livre Adaptado

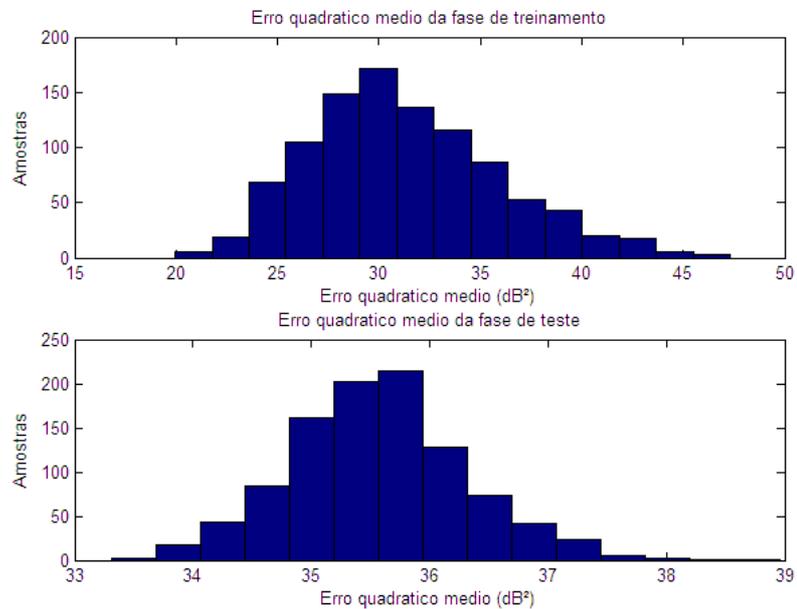


Figura 4.14: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo por Atenuação Linear

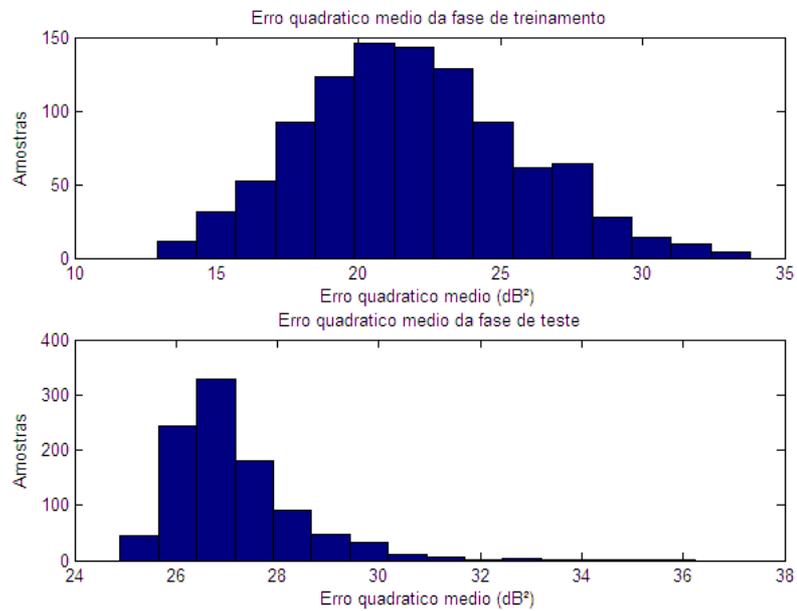


Figura 4.15: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo COST 231/Keenan Motley

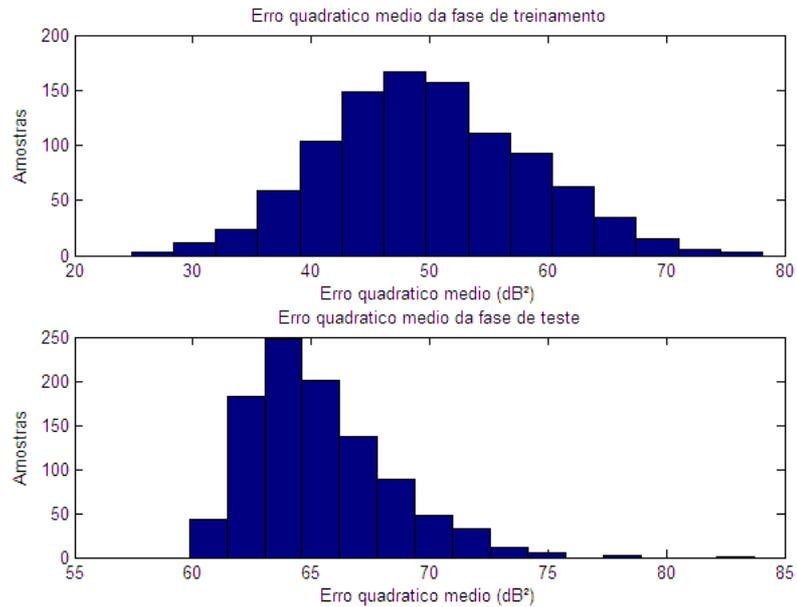


Figura 4.16: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da rede Neural Perceptron Simples

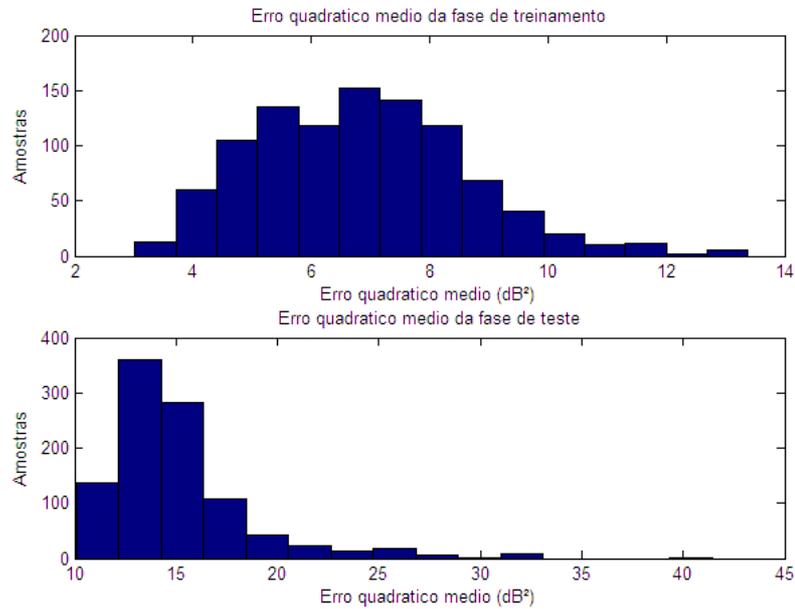


Figura 4.17: Histogramas do erro quadrático médio para as fases de treino e de teste para o modelo através da rede Neural Perceptron Multicamadas

Modelo			Espaço Livre Adaptado	Atenuação Linear	COST 231/Keenan e Motley	PS	MLP
Treino (29)	Coef. Perda	Média	2.20	2.09	1.65	-	-
		D. Padrão	0.02	0.02	0.10	-	-
	EAM (dB)	Média	5.03	4.44	3.80	5.82	2.09
		D. Padrão	0.34	0.33	0.36	0.51	0.29
	EQM (dB²)	Média	39.75	31.23	21.92	49.78	6.83
		D. Padrão	5.21	4.66	3.80	8.54	1.80
TDA (%)	Média	39.01	44.65	42.95	28.56	75.09	
	D. Padrão	6.03	5.70	7.49	6.30	8.06	
Teste (238)	EAM (dB)	Média	5.31	4.72	4.25	6.79	3.05
		D. Padrão	0.05	0.05	0.13	0.18	0.30
	EQM (dB²)	Média	45.71	35.56	27.18	65.36	15.13
		D. Padrão	0.95	0.75	1.35	2.96	3.68
	TDA (%)	Média	38.44	41.67	39.83	22.06	57.91
		D. Padrão	2.24	1.57	2.80	2.73	4.38

Tabela 4.3: Estatísticas dos modelos obtidas para a terceira simulação geral

4.7 Análise dos Resultados

4.7.1 Primeira Simulação Geral

Esta foi a simulação com maior quantidade de amostras voltadas para treinamento dos modelos dentre as três simulações gerais realizadas. Devido a esta grande quantidade de amostras utilizadas para treinamento, ao analisarmos os gráficos do erro quadrático médio para a fase de treinamento de todos os modelos, vemos que o desvio padrão é baixo, pois houve uma baixa diversidade nas amostras utilizadas. Já nos histogramas representativos da fase de teste de cada um dos modelos, já observa-se um desvio padrão bastante superior.

Analisando primeiramente os modelos semi-empíricos, vemos que os piores resultados foram obtidos pelo modelo do espaço livre adaptado, como era de se esperar, visto que, como dito anteriormente, este é um dos modelos mais simples existentes na literatura. O erro quadrático médio deste modelo foi bastante alto tanto na fase de treinamento (44.31 dB^2), quanto na fase de teste (47.01 dB^2). Os melhores resultados entre esses modelos foram obtidos pelo modelo COST 231 Keenan e Motley, com resultados consideravelmente melhores que os demais, mas ainda aquém de serem resultados satisfatórios, pois a sua taxa de acertos ainda permaneceu abaixo dos 50%. Apesar da taxa de acertos deste modelo não ser tão superior a dos demais, seu erro quadrático médio foi bastante inferior na fase de treinamento (25.83 dB^2) e na fase de teste (25.44 dB^2), sendo inclusive surpreendentemente menor na fase de teste do que na fase de treinamento.

Os resultados obtidos pela rede neural perceptron simples foram catastróficos, como já se esperava. Isto se deve ao fato de a rede neural perceptron simples ser uma rede linear e, de acordo com os modelos semi-empíricos existentes, os modelos de propagação serem não lineares, como explicado anteriormente.

Os melhores resultados globais obtidos foram, indiscutivelmente, os da rede neural perceptron multicamadas. Através dos resultados, percebe-se que a sua não linearidade conseguiu assimilar melhor a caracterização do modelo de propagação do que os demais modelos. Este modelo obteve um erro quadrático

médio baixo para a fase de treinamento (9.48 dB^2) e para a fase de teste (10.20 dB^2), sendo menores que a metade dos respectivos valores encontrados para o melhor modelo semi-empírico. A taxa de acertos também foi bastante superior às dos demais modelos, superando em aproximadamente 25% a do segundo melhor modelo tanto na fase de treinamento quanto na de teste.

4.7.2 Segunda Simulação Geral

Esta foi a simulação onde a quantidade de amostras disponíveis para treinamento foi mais próxima da quantidade de amostras disponíveis para teste. Devido a maior diversidade de amostras disponíveis na fase de treinamento, há um incremento no desvio padrão das diversas estatísticas dos modelos nesta fase. Em contrapartida, como temos uma menor diversidade de amostras para a fase de teste quando comparado com a primeira simulação geral, há um decremento do desvio padrão para as estatísticas dos modelos nesta fase.

Os resultados obtidos para os modelos semi-empíricos foram similares aos obtidos na primeira simulação geral, mas com valores do erro quadrático médio na fase de treinamento inferiores, devido a menor quantidade de amostras e, conseqüentemente, a maior facilidade de encontrar um valor do coeficiente de propagação para se adaptar a essa menor quantidade de amostras. Os piores resultados, mais uma vez, foram obtidos através do modelo do espaço livre adaptado. É importante observar a melhora dos resultados obtidos através do modelo por atenuação linear, bastante próximo dos resultados obtidos do modelo COST 231 Keenan e Motley quando se compara quanto a taxa de acertos, mas ainda pior do que o mesmo quando se compara quanto ao erro quadrático médio. No geral, o melhor modelo semi-empírico foi novamente o modelo COST 231 Keenan e Motley.

Como dito na seção anterior, mais uma vez o modelo através da rede neural perceptron simples foi ineficaz, algo que será constante devido a sua natureza linear.

Mais uma vez, os resultados obtidos pela rede neural perceptron multicamadas foram superiores quando comparados com os resultados dos demais

modelos. Comparando com a primeira simulação geral, observamos um decréscimo do erro quadrático médio na fase de treinamento, por razões já explicadas, e um acréscimo do mesmo na fase de teste, mas essa diferença é irrisória quando observa-se o custo-benefício pela utilização de um número bem menor de amostras na fase de treinamento. O mesmo ocorre quando comparamos a taxa de acertos da fase de teste com a sua respectiva da primeira simulação geral.

4.7.3 Terceira Simulação Geral

Nesta última simulação geral, o número de amostras disponíveis para treinamento foi muito inferior a quantidade de amostras disponíveis para teste. Conseqüentemente, em geral, foram obtidos os piores resultados na fase de testes entre as três simulações gerais.

Entre os modelos semi-empíricos, como ocorreu na segunda simulação geral, o modelo por atenuação linear obteve resultados semelhantes ao modelo COST 231 Keenan e Motley quanto a taxa de acertos, mas foi inferior, mais uma vez, quanto ao erro quadrático médio, tanto na etapa de treinamento como na etapa de teste. Mais uma vez o modelo com pior resultado foi o modelo do espaço livre adaptado e o melhor modelo foi o COST 231 Keenan e Motley.

Quanto às redes neurais, o modelo através da rede perceptron simples mais uma vez foi ineficaz e o modelo através da rede neural perceptron multicamadas foi o que obteve melhores resultados, mas estes foram inferiores quando comparados com as simulações gerais anteriores. Nesta simulação, durante a etapa de treinamento, a rede neural perceptron multicamadas obteve seus melhores resultados, conseguindo o mais baixo erro quadrático médio e a maior taxa de acertos de todas as simulações realizadas, mas obteve os piores índices de erro quadrático médio e taxa de acertos na fase de teste entre todas as simulações gerais das redes perceptron multicamadas. Isto se deve a pequena quantidade de amostras utilizadas para treinamento quando comparada a quantidade de amostras utilizadas para a fase de teste, já que amostras que não descrevam também a propagação pelo ambiente possam possuir uma maior significância no processo de aprendizagem da rede neural.

4.7.4 Síntese dos Resultados

Analisando os dados entre as simulações, observa-se que o modelo através da rede neural perceptron multicamadas foi o que obteve os melhores resultados sob todos os aspectos em todas as simulações gerais. Mesmo na terceira simulação geral, onde o número de amostras para treinamento era bastante inferior ao número disponibilizado na primeira simulação geral, os resultados obtidos foram bastante superiores aos resultados de qualquer outro modelo na primeira simulação geral (exceto o modelo através da rede neural perceptron multicamadas, obviamente) . Pode-se tentar explicar isso pelo fato da presença de ruído e pelo *layout* do ambiente no processo de amostragem. Como foi observado, não foi incluída a presença de ruído na formulação de nenhum dos modelos apresentados neste trabalho, mas a rede neural é capaz de aprender mesmo com a presença de ruído, diluindo sua influência ao longo do processo de aprendizagem, fato que não é possível nos modelos semi-empíricos, tornando-os mais suscetíveis a erros pelo ruído. Além disso, ainda há o desvanecimento presente nas proximidades de obstáculos, que também pode ser mais facilmente aprendido pela rede neural quando comparado aos modelos semi-empíricos, que só possuem a capacidade de ajustar o coeficiente de perda de percurso, ao passo que as redes neurais possuem uma maior flexibilidade de ajuste de parâmetros.

5 CONCLUSÃO

O foco deste trabalho foi a busca de um modelo de propagação do sinal em redes *wireless indoor*. Esse tipo de sinal sofre influências dos obstáculos, do *layout* do ambiente, do tipo de material formador dos obstáculos, do número de pisos, entre outros. Por causa dessas e de outras particularidades, modelos para este tipo de sistema, apesar de já terem sido muito analisados, ainda permanecem sendo um problema de difícil solução.

Com o intuito de criar um modelo que melhor descrevesse a propagação do sinal nesse tipo de sistema, buscando colaborar em novos projetos de redes *indoor*, foram desenvolvidos neste trabalho preditores neurais, tendo seus resultados comparados com modelos semi-empíricos já existentes na literatura. As medidas de propagação, o ajuste dos modelos semi-empíricos e a criação dos preditores neurais constituem-se nas principais contribuições do presente trabalho. Os modelos projetados através de redes neurais artificiais mostraram ser completamente viáveis e factíveis, tendo um custo computacional similar aos modelos semi-empíricos e baixo tempo de resposta, sendo menor que 1 minuto para a quantidade de amostras utilizadas (267 amostras no total). Os modelos teóricos e semi-empíricos existentes, muitas vezes, não refletem a realidade do problema; o ambiente mostra-se muito mais complexo do que a abordagem adotado por estes modelos. Nesse ponto, a rede neural traz uma enorme vantagem, dado que ela se adapta totalmente às amostras que são passadas para a aprendizagem da mesma.

Analisando os resultados obtidos durante a pesquisa, observa-se que o preditor neural utilizando uma rede MLP se mostrou extremamente mais eficaz que os demais modelos projetados. Mesmo em casos extremos, como por exemplo utilizando uma quantidade de amostras muito maior para treinamento dos modelos semi-empíricos do que de amostras para treinamento da rede neural MLP (como na

terceira simulação geral), obtivemos melhores resultados através do preditor neural MLP. Esta melhoria dos resultados foi significativa, tendo o preditor neural MLP resultados qualitativos mais de duas vezes melhor que os obtidos pelo melhor modelo semi-empírico projetado. Os resultados obtidos, apesar de mostrarem que o problema não foi completamente resolvido, foram relevantes, impulsionando-nos a continuar a pesquisa nessa área, buscando um modelo que cada vez mais melhor caracterize este tipo de sistema.

Como continuação deste trabalho, sugere-se duas vertentes:

- Pode-se dar seguimento aos estudos abordando uma gama maior de arquiteturas de redes neurais, modificando-se sua quantidade de neurônios, sua forma de aprendizagem, suas funções de ativação, com a finalidade de se obter resultados comparativos entre outros modelos neurais, para verificação de um modelo que melhor se adeque a este tipo de sistemas do que o modelo projetado no presente trabalho.
- Uma outra abordagem que pode ser realizada diz respeito aos parâmetros mais significativos num processo de propagação *indoor*. No presente trabalho, os parâmetros de cada amostra foram descritos na seção 4.4.4 para os treinamentos das duas redes neurais projetadas. Em trabalhos futuros, pode-se projetar diversos modelos neurais utilizando parâmetros de entrada diferentes, buscando um estudo sobre a relevância dos mesmos para o melhor funcionamento do sistema. Este é um estudo fundamental para o crescimento de trabalhos nesta área de pesquisa, visto que pode ser aplicado a uma gama de trabalhos muito mais ampla, não só a preditores neurais.

Apêndices

1 Ferramenta de Simulação

Como todos os modelos projetados neste trabalho foram implementados no *software MatLab* 6.5, foi criada uma interface com o usuário para a fácil simulação dos modelos criados, através da qual pode-se obter os resultados de cada um dos modelos de forma rápida, para efeito de comparação entre os mesmos.

Através desta interface, antes de simular cada modelo, deve se definir o número de amostras referentes a fase de treinamento (entre 6% e 96% do total de amostras) e o limiar para o cálculo da taxa de acertos (de 0.1 a 20 dB), além do número de épocas de treinamento para os modelos que utilizam redes neurais. Como resultados da simulação de cada modelo, temos os quais já foram mostrados na tabela de resultados das simulações gerais deste trabalho (erro absoluto médio, erro quadrático médio e taxa de acertos, para ambas as fases, além do coeficiente de perda de percurso, exclusivo para os modelos semi-empíricos), além de gráficos com o valor da potência calculada para cada amostra (diferenciando as amostras referentes a fase de treinamento das amostras referentes a fase de teste), o valor do erro para cada amostra (também diferenciando as amostras utilizadas para treinamento e as utilizadas para teste), o erros absolutos das amostras ordenados de forma crescente (similar a uma função de distribuição cumulativa), tanto para a fase de treinamento quanto para a fase de teste, e o histograma do erro absoluto, também para as duas fases, todos referentes ao modelo simulado. Através da interface, também pode-se verificar os gráficos do erro quadrático médio após cada época de treinamento para os modelos que utilizam redes neurais, com a finalidade de se verificar o decremento do mesmo, mostrando uma “aprendizagem” da rede neural.

A.1, vemos um *print screen* da interface com o usuário e nas figuras A.2 a A.7 observamos exemplos dos resultados gráficos obtidos para uma simulação utilizando o modelo através da rede neural perceptron multicamadas utilizando 131 amostras para treinamento, 136 amostras para teste em um total de 250 épocas de treinamento.

Predição do Sinal em Redes Wireless através de Redes Neurais Artificiais

File Edit View Insert Tools Window Help

Modelo - Espaço Livre* Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB TREINAMENTO Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Coef. de Perda de Percuro: <input type="text"/> dB Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Taxa de Aceitos: <input type="text"/> % <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos		Modelo - Rede Neural MLP: Tipo de Rede Neural MLP: <input type="radio"/> Por Epoca: <input type="radio"/> Por Erro Quadratico Medio TREINAMENTO Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB - Caso seja por Epocas: Numero de Epocas Total: <input type="text" value="400"/> - Caso seja por Erro Quad. Medio: Erro Quad. Medio Alvo: <input type="text" value="15"/> dB ² Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % TESTE Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Epoca Atual: <input type="text"/> <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos <input type="button" value="Grafico Erro Quad. Medio x Epocas"/>	
Modelo - Atenuacao Linear* Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB TREINAMENTO Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Coef. de Perda de Percuro: <input type="text"/> dB Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Taxa de Aceitos: <input type="text"/> % <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos		Modelo - Rede Neural Perceptron Simples Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB Numero de Epocas Total: <input type="text" value="400"/> Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % TESTE Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Epoca Atual: <input type="text"/> <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Graficos off <input type="button" value="Grafico Erro Quad. Medio x Epocas"/>	
Modelo - COST 231/Keenan Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB TREINAMENTO Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Coef. de Perda de Percuro: <input type="text"/> dB Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Taxa de Aceitos: <input type="text"/> % <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos		Modelo - Rede Neural MLP: Tipo de Rede Neural MLP: <input type="radio"/> Por Epoca: <input type="radio"/> Por Erro Quadratico Medio TREINAMENTO Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB - Caso seja por Epocas: Numero de Epocas Total: <input type="text" value="400"/> - Caso seja por Erro Quad. Medio: Erro Quad. Medio Alvo: <input type="text" value="15"/> dB ² Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % TESTE Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Epoca Atual: <input type="text"/> <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos <input type="button" value="Grafico Erro Quad. Medio x Epocas"/>	
Modelo - Espaço Livre* Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB TREINAMENTO Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Coef. de Perda de Percuro: <input type="text"/> dB Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Taxa de Aceitos: <input type="text"/> % <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Nao mostrar graficos		Modelo - Rede Neural MLP: Tipo de Rede Neural MLP: <input type="radio"/> Por Epoca: <input type="radio"/> Por Erro Quadratico Medio TREINAMENTO Definições: Percentagem de Amostras: <input type="text" value="90"/> % Limiar p/ Taxa de Aceitos: <input type="text" value="3"/> dB - Caso seja por Epocas: Numero de Epocas Total: <input type="text" value="400"/> - Caso seja por Erro Quad. Medio: Erro Quad. Medio Alvo: <input type="text" value="15"/> dB ² Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % TESTE Resultados: Numero de Amostras Utilizadas: <input type="text"/> <input type="text"/> <input type="text"/> Erro Absoluto Medio: <input type="text"/> dB Erro Quadratico Medio: <input type="text"/> dB ² Taxa de Aceitos: <input type="text"/> % Epoca Atual: <input type="text"/> <input type="button" value="Simular"/> <input type="button" value="Limpar"/> <input type="radio"/> Graficos off <input type="button" value="Grafico Erro Quad. Medio x Epocas"/>	

Informações Gerais



Total de Amostras:

Figura A.1: Interface com o usuário do programa para simulação dos modelos criados

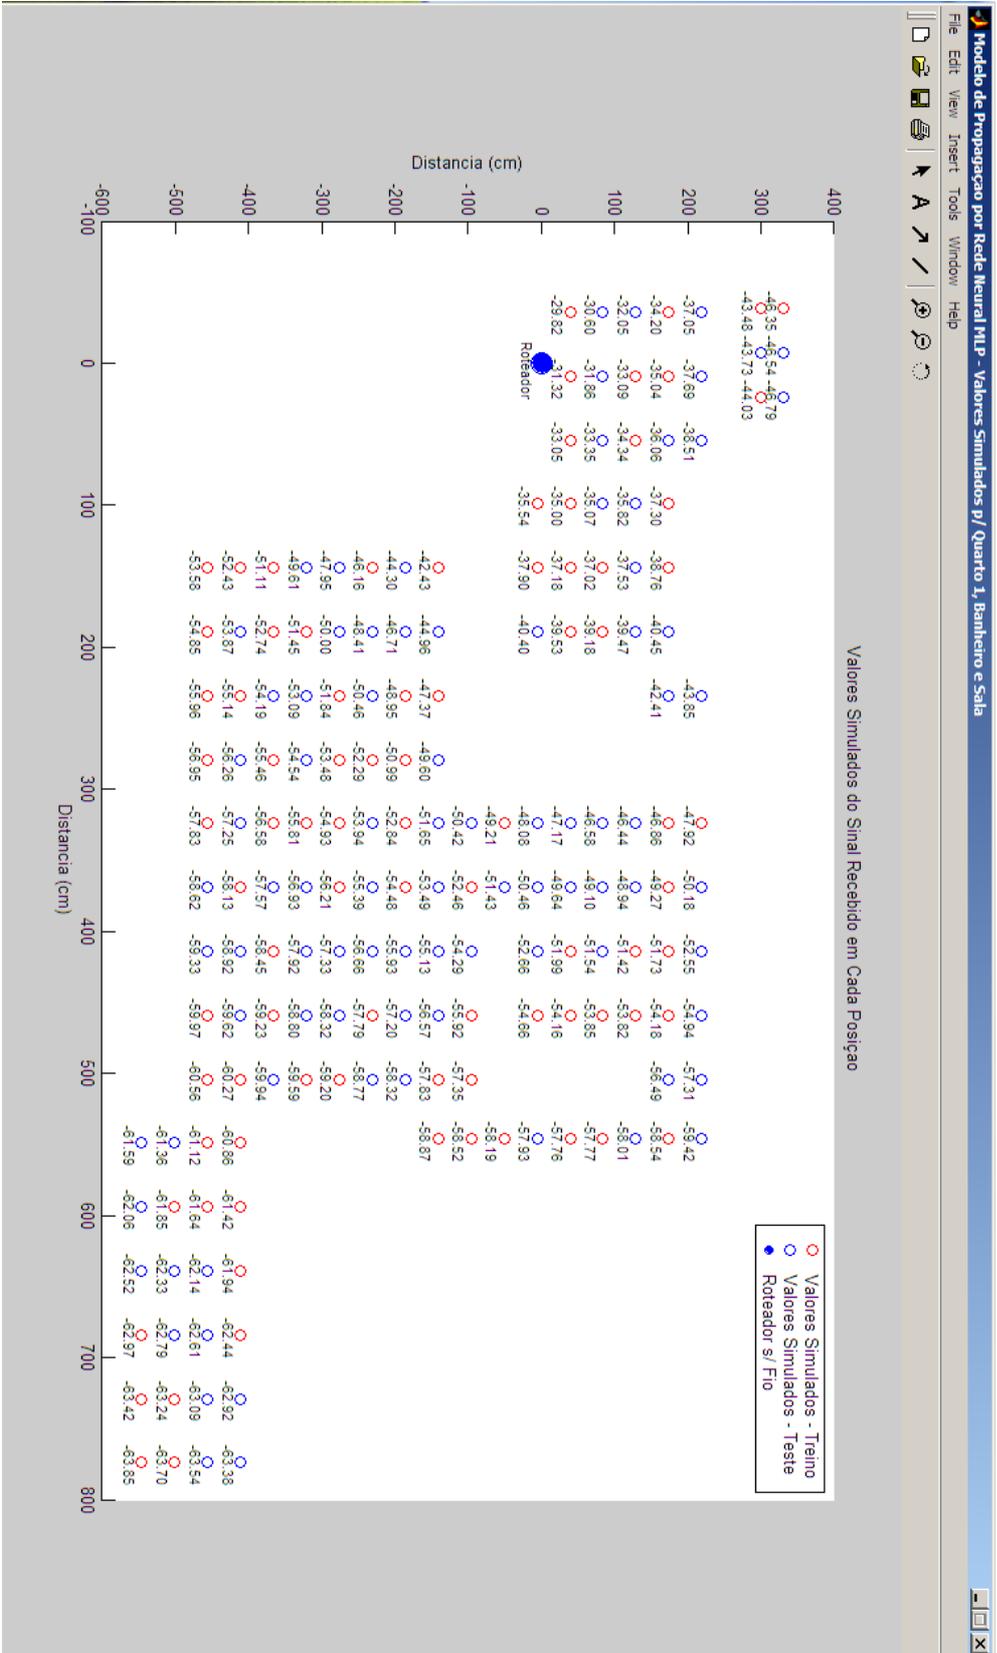


Figura A.2: Valores de potência gerados pelo modelo através da rede neural perceptron multicamadas para o quarto 1, banheiro e sala

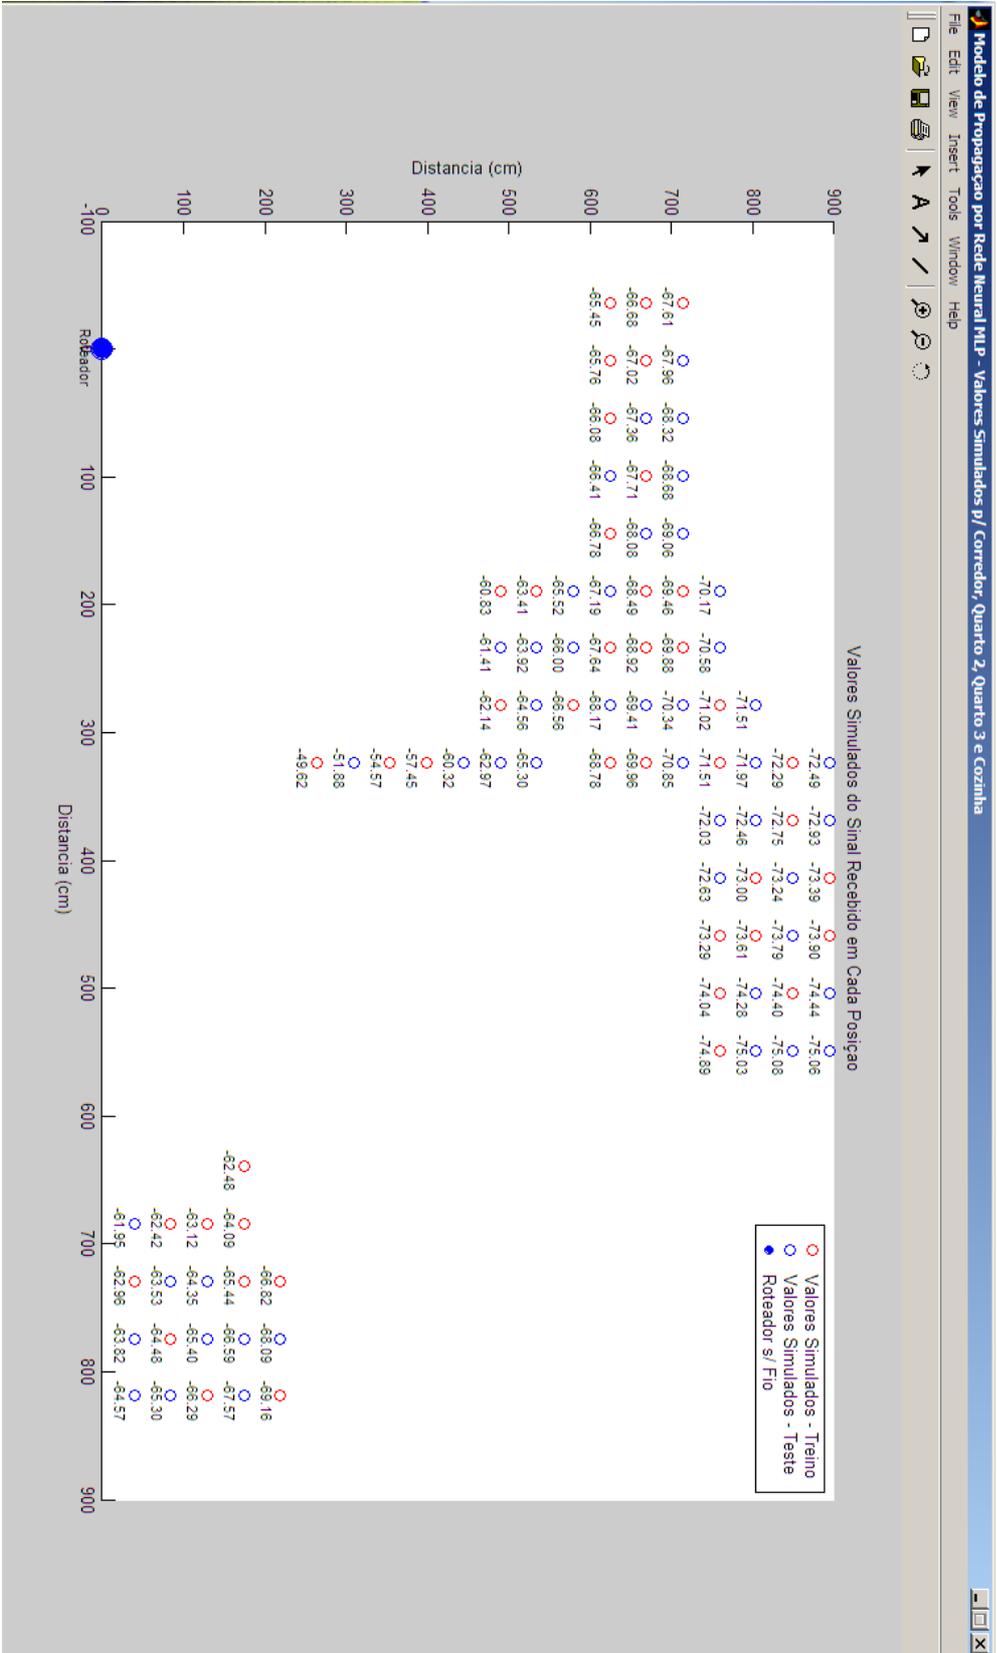


Figura A.3: Valores de potência gerados pelo modelo através da rede neural perceptron multicamadas para o corredor, quarto 2, quarto 3 e cozinha

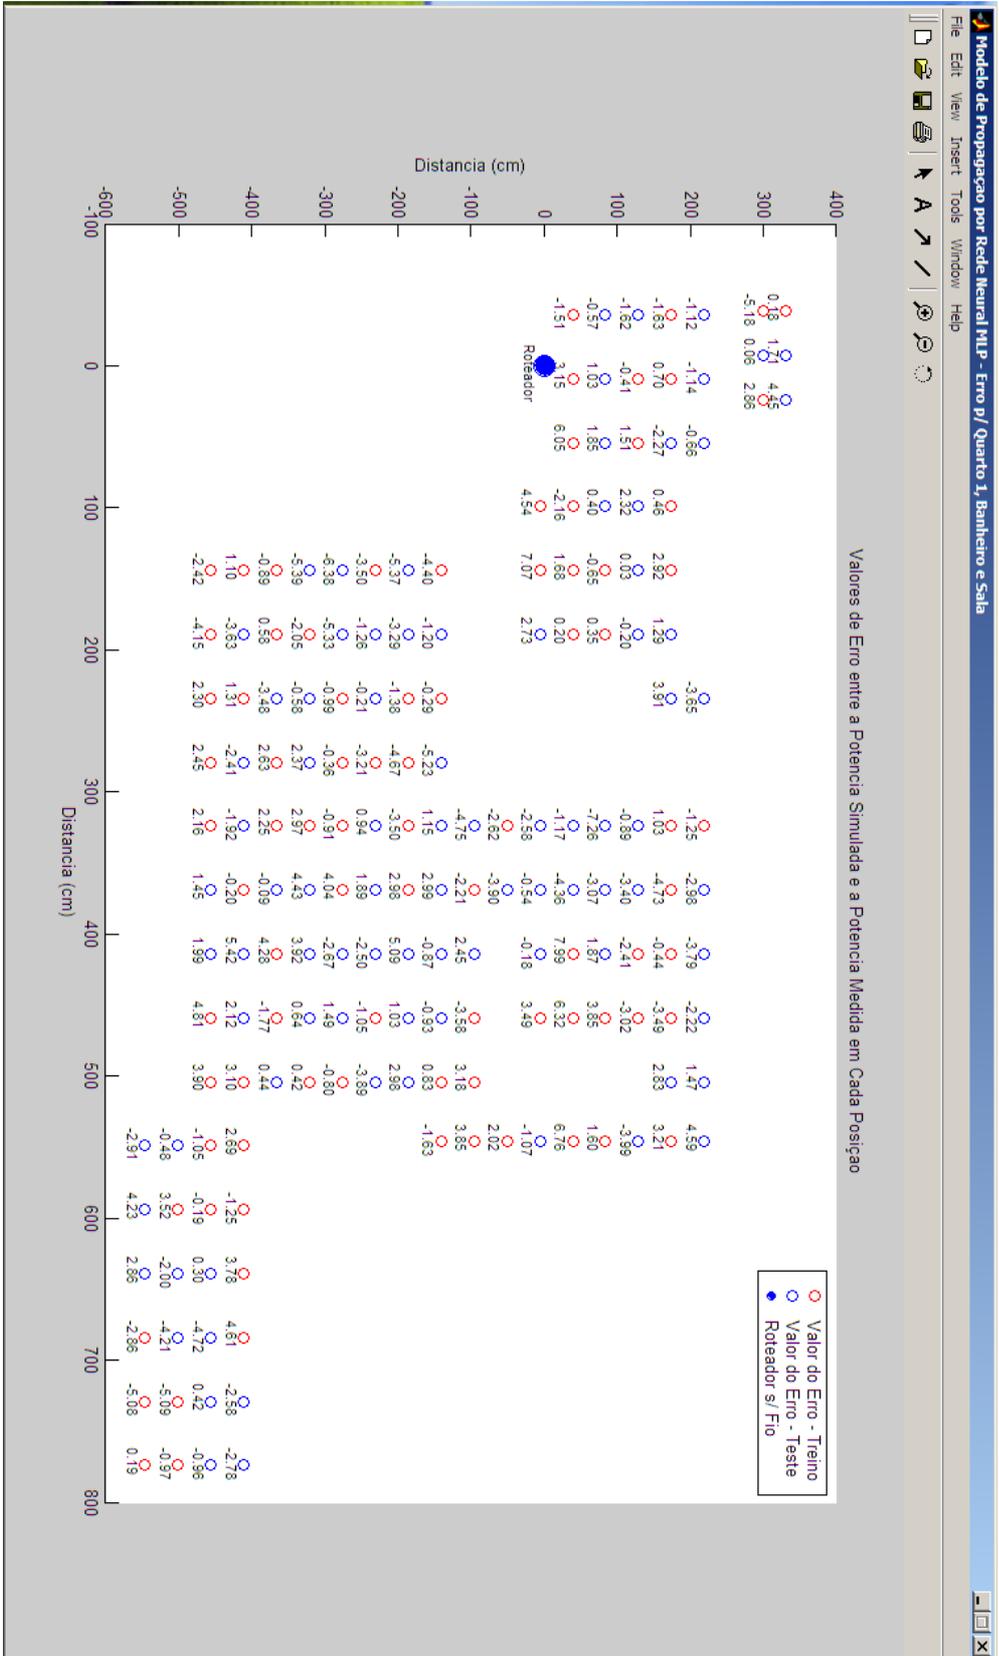


Figura A.4: Erros do valor de potência gerados pelo modelo através da rede neural perceptron multicamadas para o quarto 1, banheiro e sala

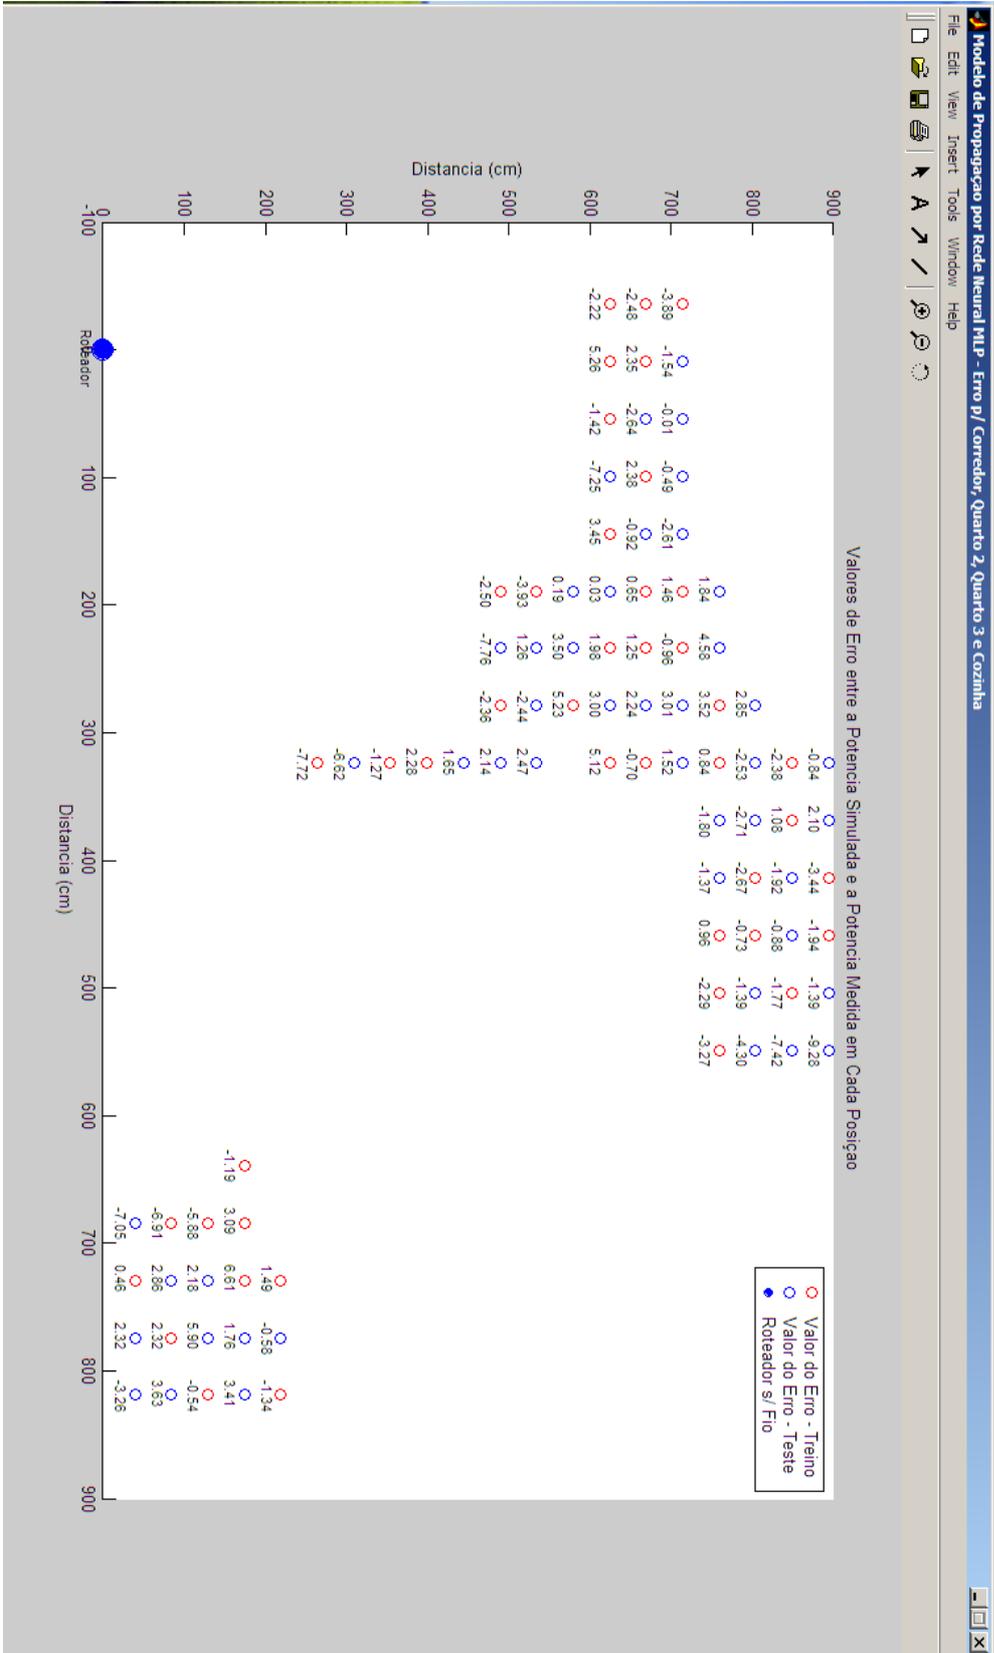


Figura A.5: Erros do valor de potência gerados pelo modelo através da rede neural perceptron multicamadas para o corredor, quarto 2, quarto 3 e cozinha

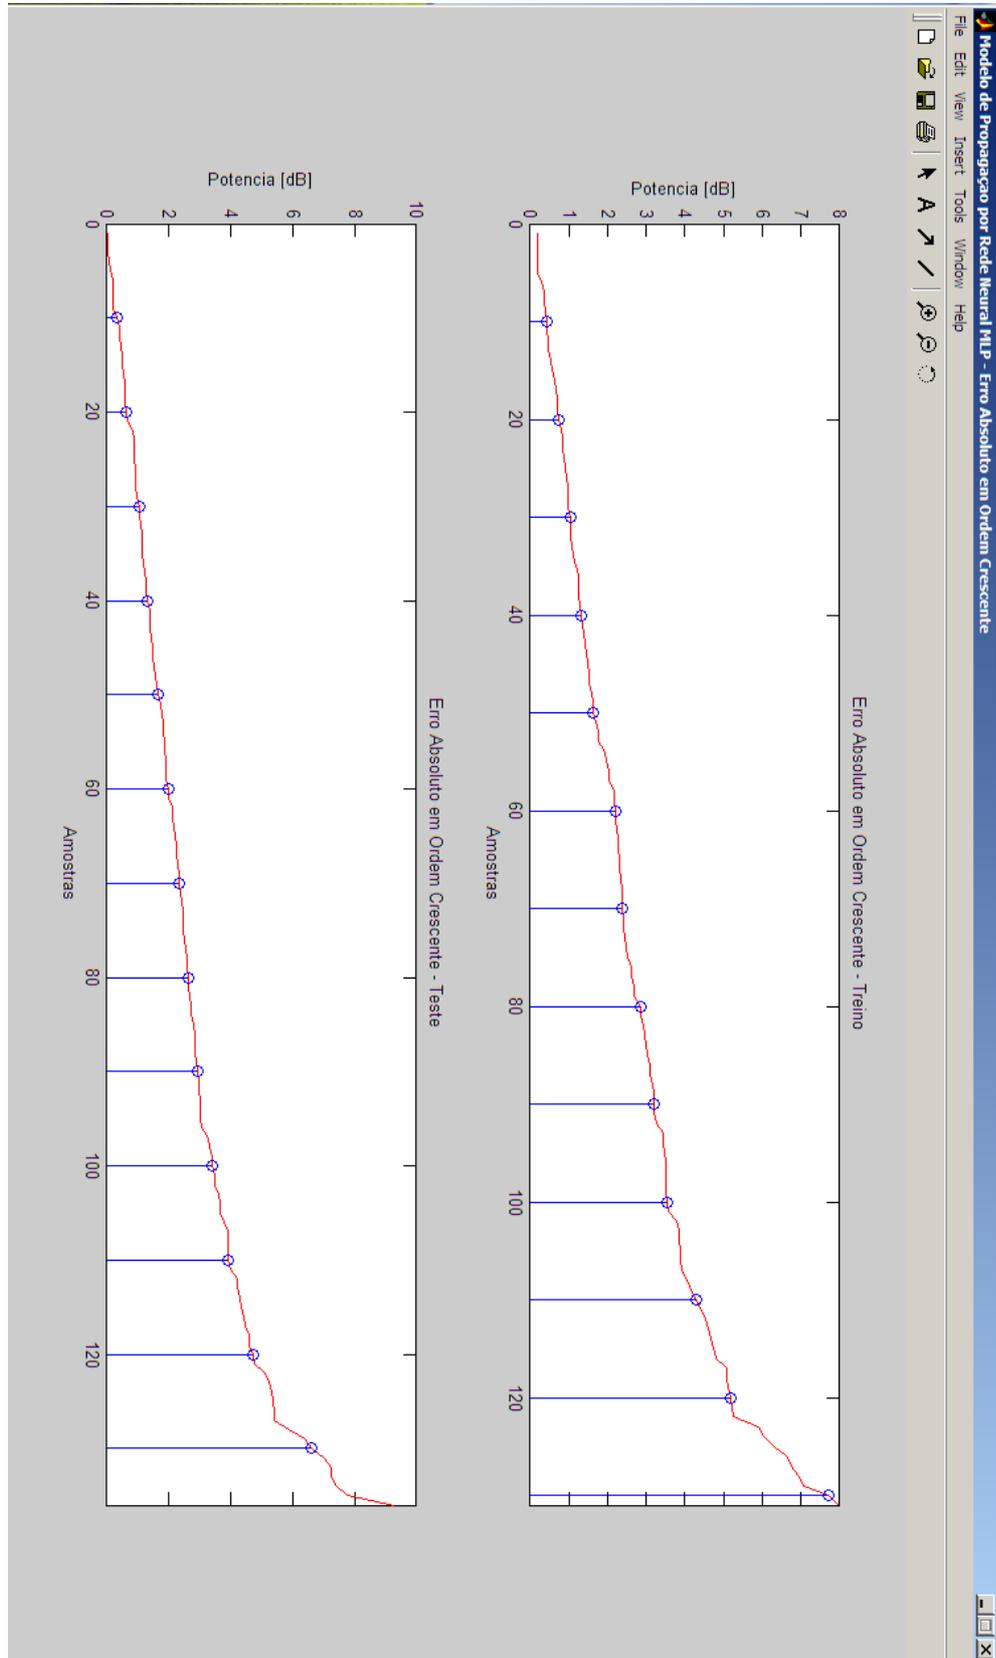


Figura A.6: Erro absoluto das amostras em ordem crescente gerados pelo modelo através da rede neural perceptron multicamadas para a fase de treinamento de para a fase de teste

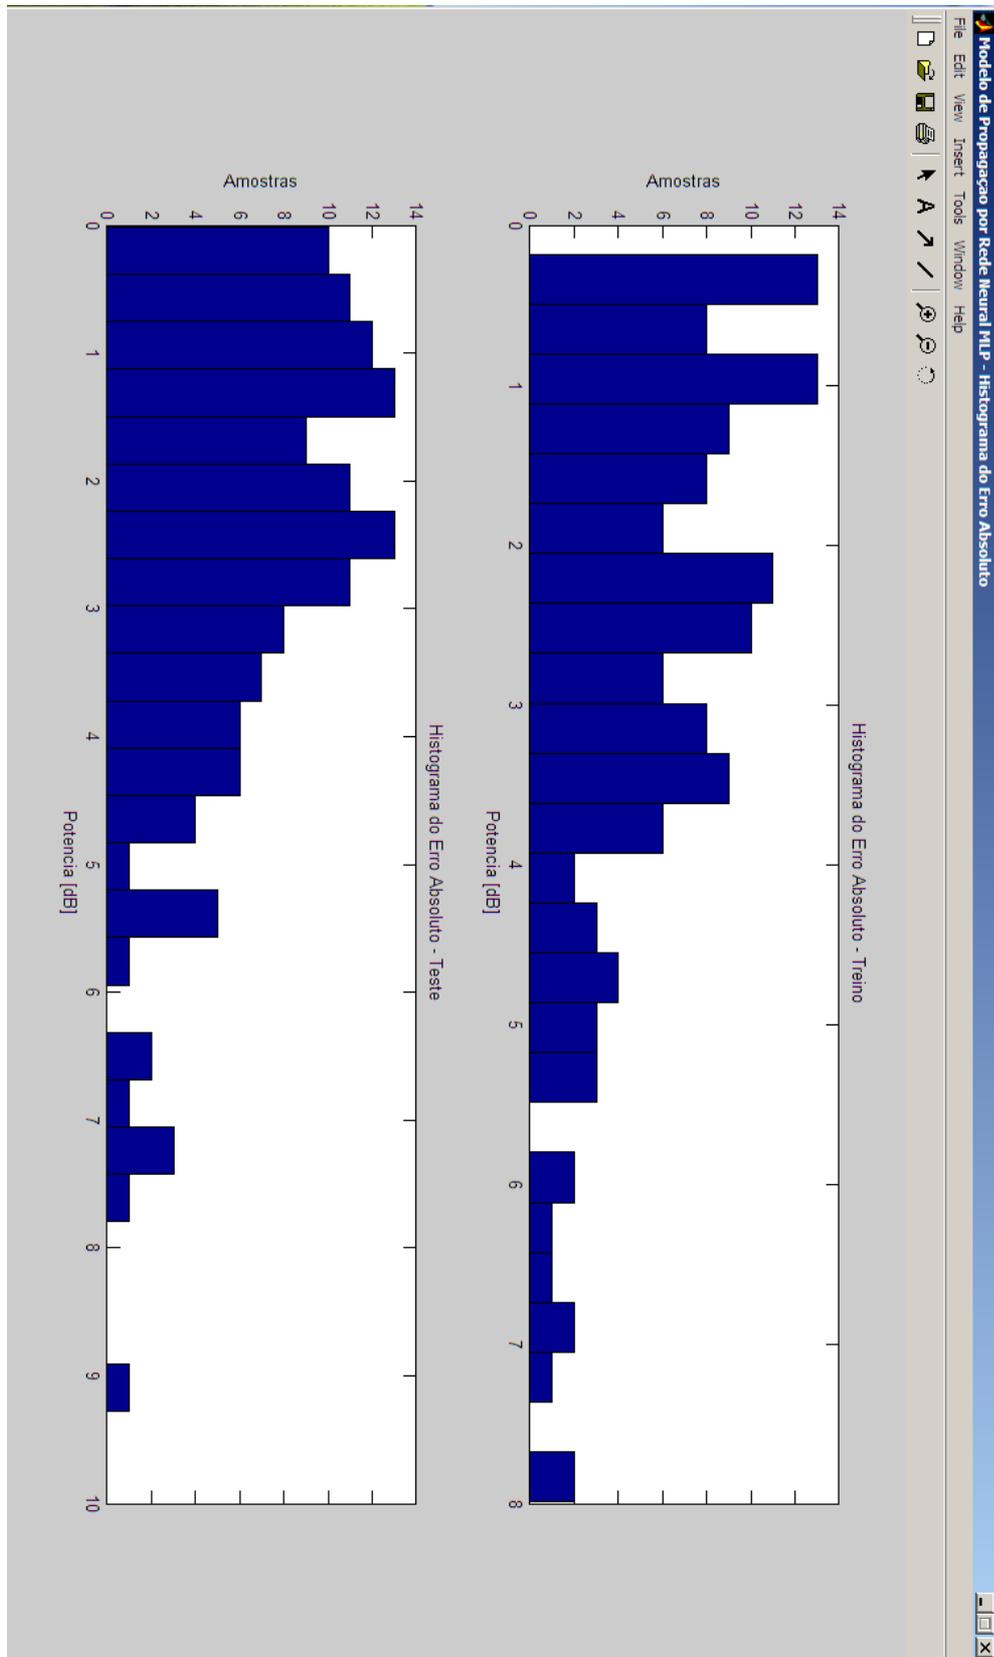


Figura A.7: Histograma do erro absoluto de cada amostra gerado pelo modelo através da rede neural perceptron multicamadas para a fase de treinamento e para a fase de teste

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] LOPES, R., FREIXO, P., SERRADOR, A., *Modelo de Propagação para WLANs*, Instituto Superior de Engenharia de Lisboa, Departamento de Engenharia de Eletrônica e Telecomunicações e de Computadores, Lisboa, Portugal, 2003.
- [2] MELO, Kátia, *Predição da Intensidade do Campo Elétrico da Onda de Superfície Utilizando Redes Neurais Artificiais*. Tese (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Faculdade de Tecnologia, Universidade de Brasília, Brasília, Brasil, 2008.
- [3] VIEIRA, R.C., ROISENBERG, M., *Redes Neurais Artificiais: um breve tutorial*. Laboratório de Conexionismo e Ciências Cognitivas, Universidade Federal de Santa Catarina, Florianópolis, Brasil, 2003.
- [4] HAYKIN, S., *Redes Neurais – Princípios e Prática*. 2ª. edição, Bookman, Porto Alegre, Brasil, 2001.
- [5] BRAGA, A., CARVALHO, A., LUDEMIR, T., *Redes Neurais Artificiais: Teoria e Aplicações*. Livros Técnicos e Científicos, Rio de Janeiro, Brasil, 2000.
- [6] NAJNUDEL, Marcelo, *Estudo de Propagação em Ambientes Fechados para o Planejamento de WLANs*. Tese (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil, 2004.
- [7] RAPPAPORT, T.S., *Wireless Communications: Principles and Practice*. 2nd edition, Prentice Hall, New York, USA, 2002.
- [8] COST 231, *Digital Mobile Radio Towards Future Generation Systems*, Final Report – European Commission, 1999.

[9] Notas de aula da disciplina Sist. de Comunicações Móveis I, Eng. de Teleinformática, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2008.