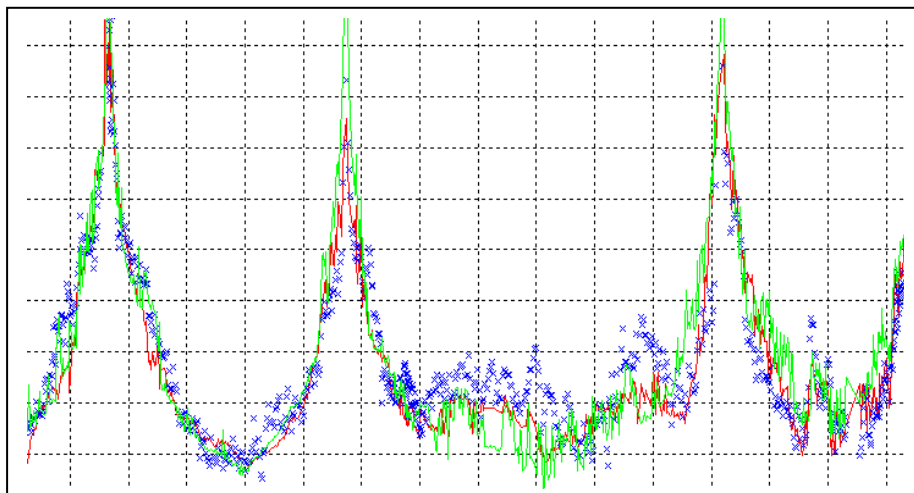


INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA
Área Departamental de Engenharia de Eletrónica e
Telecomunicações e de Computadores



Estimação de cobertura rádio em GSM-R através de
Redes Neurais

Tiago Branch Sampaio Correia

(Licenciado)

Trabalho Final de Mestrado para Obtenção do Grau de Mestre em Engenharia de Eletrónica e
Telecomunicações

Orientadores:

Prof. Nuno António Fraga Juliano Cota

Prof. Hélder Jorge Pinheiro Pita

Júri:

Presidente: Prof. Pedro Manuel de Almeida Carvalho Vieira

Vogais: Prof. António José Castelo Branco Rodrigues

Prof. Hélder Jorge Pinheiro Pita

Dezembro de 2014

Agradecimentos

Gostaria de agradecer a todos que me apoiaram durante esta dissertação, aos Professores Nuno Cota e Hélder Pita por todo o acompanhamento e supervisão que me deram ao longo deste trabalho, à REFER-Telecom por ter disponibilizado toda informação necessária e à minha família por me terem apoiado durante este ano letivo.

Resumo

Atualmente estão a ser implementados sistemas GSM-R nas linhas ferroviárias de Portugal e para isto é necessário obter uma estimativa de sinal o mais precisa possível de forma a minimizar ao máximo o custo de instalação dos sistemas.

Com base em medidas feitas anteriormente, esta dissertação propõe um método de estimativa de sinal alternativo aos modelos de estimação de cobertura rádio utilizando redes neuronais. Com medidas de várias linhas, implementou-se várias redes neuronais utilizando um método de treino supervisionado, ou seja, as redes conseguem aprender o comportamento de sinal em linhas ferroviárias com base nos parâmetros do modelo e nos parâmetros de terreno.

Numa primeira experiência implementou-se uma rede neuronal multicamada, seguindo os vários passos do seu dimensionamento, para obter uma solução ótima na estimação de cobertura rádio em cada um dos cenários estudados. Esta experiência revelou uma diminuição do erro obtido na estimação de sinal apresentando-se como uma melhor solução em relação aos métodos anteriormente considerados. Numa segunda experiência pretendeu-se seguir uma abordagem diferente treinando um perceptrão com os vários parâmetros e fatores corretivos do modelo de Okumura-Hata de forma a comparar os resultados com a rede treinada anteriormente. Esta segunda experiência apresentou um aumento do erro em relação à anterior mas ainda apresentando resultados validos na estimação de sinal.

Numa fase final pretendeu-se implementar uma aplicação, baseada em redes neuronais, que apresente uma solução generalizada para todos os cenários considerados. Para isto treinou-se uma rede neuronal competitiva com o objetivo de classificar as várias amostras em diferentes tipos de ambiente. Definidos os ambientes, treinou-se uma rede neuronal otimizada para cada um desses ambientes. A aplicação foi testada e apresentou um pequeno aumento do erro em relação às redes otimizadas para cada cenário mas apresenta um erro menor em relação aos métodos utilizados anteriormente provando ser uma melhor solução.

Palavras-chave

Redes neuronais; Estimação de sinal; Aprendizagem Supervisionada;

Abstract

Currently GSM-R systems are being implemented in Portugal's railway lines. For this it is necessary to obtain an estimate of the signal as precisely as possible in order to minimize as much as possible the cost of installation of the systems.

Based on measurements previously made, this thesis proposes an alternative method of estimating the signal using neural networks. With the measurements of the various lines various neural networks were implemented, using a method of supervised training, in other words the networks manage to learn the signal behaviour of railway lines based on the parameters of the model and the terrain parameters.

In a first experiment a multi-layered neural network was implemented, following the various steps of its design to obtain an optimal solution in the estimation of radio coverage in each of the scenarios investigated. This experiment revealed a decrease in error obtained in the estimation of the signal, presenting a better solution in relation to the previously considered methods. In a second experiment a different approach was followed, training a perceptron with the various parameters and corrective factors of the Okumura-Hata model to compare the results with the previously trained network. This second experiment presented an increase in error in relation to the previous one but obtaining valid results in the estimation of signal.

In a final phase an application based on neural networks was to be implemented, presenting a generalized solution for all the scenarios considered. For this a competitive neural network was trained with the objective of classifying the various samples into different types of environment. Having defined the environments, an optimized neural network was trained for each one. The application was tested and presented a small increase in error in relation to the optimized networks for each scenario, but presented a smaller error in relation to the previous methods proving to be a better solution.

Keywords

Neural networks; Radio signal estimation; Supervised learning;

Índice

1	Introdução	1
1.1	Enquadramento.....	1
1.2	Motivação.....	2
1.3	Objetivos	2
1.4	Estrutura do relatório.....	3
2	Propagação Rádio em Comunicações Ferroviárias.....	5
2.1	Modelo de Propagação Okumura-Hata	5
2.1.1	Cálculo de atenuação	6
2.1.2	Altura efetiva	7
2.1.3	Atenuação por Difração.....	8
2.1.4	Atenuação pela presença de vegetação.....	9
2.1.5	Influência de Água.....	10
2.1.6	Ondulação do terreno.....	11
2.1.7	Posição na ondulação do terreno	12
2.1.8	Correção por Orientação ou Ruas Radiais.....	12
2.2	Casos de estudo e medidas rádio.....	13
2.2.1	Linha de Évora.....	13
2.2.2	Linha de Cascais	15
2.2.3	Linha do Algarve	16
2.2.4	Resumo das Medidas	17
2.2.5	Ferramenta de Perdição de Sinal	18
3	Redes Neurais	19
3.1	Introdução às Redes Neurais	19
3.2	Modelo de um neurónio	20
3.3	Funções de Ativação	21
3.4	Algoritmo de Aprendizagem.....	21

3.5	Rede Neuronal Multicamada.....	22
3.6	Algoritmo de Retro Propagação	24
3.6.1	Algoritmo de Retro Propagação de Levenberg-Marquardt	25
3.7	Aprendizagem Competitiva.....	26
4	Implementação.....	29
4.1	Considerações prévias	29
4.1.1	Conjunto de Amostras de Treino.....	29
4.1.2	Conjunto de Amostras de Validação	30
4.1.3	Conjunto de Amostras de Teste.....	30
4.2	Parâmetros de Entrada.....	30
4.3	Processamento adicional	31
4.3.1	Normalização.....	31
4.4	Função de Ativação.....	31
4.5	Algoritmo de Aprendizagem.....	32
4.5.1	Parametrização do algoritmo de aprendizagem.....	32
4.6	Critérios de Paragem	32
4.6.1	Número Máximo de Épocas	33
4.6.2	Número Máximo de Validações Falhadas.....	33
4.6.3	Gradiente Mínimo.....	33
4.6.4	Coeficiente de Aprendizagem Máximo.....	34
4.7	Número de Neurónios	34
4.8	Análise de Parâmetros.....	35
4.9	Redes Neurais Otimizadas para cada Linha.....	36
4.10	Aproximação à função de Okumura-Hata.....	37
4.11	Classificação de Ambientes	39
4.12	Redes Neurais com Classificação de Ambientes	39
5	Análise de Resultados.....	43
5.1	Estatística do Erro	43

5.2	Análise de parâmetros	44
5.3	Redes Otimizadas para cada Cenário	46
5.3.1	Linha de Évora.....	47
5.3.2	Linha de Cascais	48
5.3.3	Linha do Algarve	49
5.3.4	Resumo de Resultados de Cada Linha	51
5.4	Alternativa Utilizando um Perceptrão	52
5.5	Classificação de Ambientes	53
5.6	Classificação de Parâmetros.....	54
5.7	Análise de Desempenho da Aplicação	54
5.8	Resultados Gerais	56
6	Conclusões	59
6.1	Trabalho Desenvolvido	59
6.2	Resultados Obtidos.....	59
6.3	Trabalho Futuro.....	60

Índice de Figuras

Figura 1 - Altura efetiva (ITU-R).	7
Figura 2 - Método de Deygout.....	8
Figura 3 - Influência da água.	10
Figura 4 - Ondulação do terreno.	11
Figura 5 - Posição na ondulação do terreno.....	12
Figura 6 - Linha ferroviária de Évora.	14
Figura 7 - Viagens de teste na linha de Évora.	14
Figura 8 - Medidas obtidas na 1ª viagem de teste na linha de Évora.....	15
Figura 9 - Estação base GSM-R da linha de Cascais.....	15
Figura 10 - Linha ferroviária de Cascais.....	16
Figura 11 - Linha ferroviária do Algarve.....	17
Figura 12 - Viagens de teste na linha do Algarve.....	17
Figura 13 - Modelo de um neurónio.	20
Figura 14 - Funções de ativação.	21
Figura 15 - Rede Neuronal Multicamada.....	23
Figura 16 - Método do gradiente descendente.	24
Figura 17 - Algoritmo de Retro Propagação.....	25
Figura 18 - Rede Neuronal Competitiva.....	27
Figura 19 - Exemplo de classificação	27
Figura 20 - Processamento adicional.	31
Figura 21 - Função de ativação.....	31
Figura 22 - Evolução do erro durante a fase de treino.....	33
Figura 23 - Rede Neuronal Multicamada.....	34
Figura 24 - RMSE vs Número de neurónios.....	35
Figura 25 - Rede neuronal para análise de parâmetros.	36
Figura 26 - Rede neuronal com classes.....	37
Figura 27 – Perceptrão.	38
Figura 28 - Aplicação baseada em redes neuronais.	40
Figura 29 - Diagrama de blocos.....	41
Figura 30 - Rede neuronal após classificação.....	41
Figura 31 - Ganho por parâmetro.....	45

Figura 32 - Rede neuronal otimizada para cada cenário.....	46
Figura 33 – Best Server, linha de Évora	48
Figura 34 - Best Server, linha de Cascais.	49
Figura 35 - Best Server, linha do Algarve	51
Figura 36 - Best Server, linha de Évora.	57
Figura 37 - Best Server, linha de Cascais.	57
Figura 38 - Best Server, linha do Algarve.	58

Índice de tabelas

Tabela 1 - Parâmetros de calibração do modelo.	7
Tabela 2 - Parâmetros de calibração do método de Deygout.....	9
Tabela 3 - Parâmetros de calibração do modelo de Weissberger.	10
Tabela 4 - Parâmetros de calibração do fator corretivo <i>Kmp</i>	11
Tabela 5 - Parâmetros de calibração do fator corretivo <i>Kth</i>	11
Tabela 6 - Parâmetros de calibração do fator corretivo <i>Khp</i>	12
Tabela 7 - Parâmetros de calibração do fator corretivo <i>Kacl</i>	13
Tabela 8 – Estações base na linha de Cascais e respectivas frequências.....	16
Tabela 9 - Estatísticas das medidas retiradas das três linhas.....	18
Tabela 10 - Divisão de amostras.....	29
Tabela 11 - Parâmetros de entrada.....	30
Tabela 12 - Parametrização do coeficiente de aprendizagem.....	32
Tabela 13 - Classificação de ambiente.....	39
Tabela 16 - Resultado da análise de parâmetros.....	44
Tabela 17 - Definição das classes de parâmetros.....	45
Tabela 18 - Estatísticas de treino na linha de Évora.....	47
Tabela 19 – Erro obtido na Linha de Cascais.....	47
Tabela 18 - Estatísticas de treino na linha de Cascais.....	48
Tabela 19 – Erro obtido na linha de Cascais.....	49
Tabela 20- Estatísticas de treino na linha do Algarve.....	50
Tabela 23 - Erro obtido na linha do Algarve.....	50
Tabela 24 - Resumo de resultados de redes otimizadas para cada cenário.....	51
Tabela 25 - Resultados das diferentes abordagens.....	52
Tabela 26- Estatísticas da fase de treino de rede competitiva.....	53
Tabela 27 - Descrição dos ambientes definidos.....	53
Tabela 28 - Resultado de análise de parâmetros em diferentes ambientes.....	54
Tabela 29 - Definição de Classes de parâmetros para cada Ambiente.....	54
Tabela 30 - Número de amostras por ambiente.....	55
Tabela 31 - Erro obtido nos vários ambientes.....	55
Tabela 32 - Número de amostras por ambiente.....	56
Tabela 33 – Comparação de resultados finais.....	56

Lista de Acrónimos

ANACOM – Autoridade nacional para as comunicações

BTS – *Base transceiver Station*

ERTMS - *European Rail Traffic Management System*

ESD – *Estimated standard deviation*

GSM – *Global System for Mobile*

GSM-R - *Global System for Mobile Communications – Railway*

ISEL – Instituto Superior de Engenharia de Lisboa

ITU-R – *International telecommunication union – Radio communication sector*

LP – *Path loss.*

ME – *Mean error*

MEET – Mestrado em Engenharia eletrónica de Telecomunicações

MSE – *Mean squared error*

PK – Ponto quilométrico

PN - Passagem de nível

REFER E.P. - Rede Ferroviária Nacional, entidade pública

RMSE – *Root mean squared error*

Lista de Símbolos

β : Rácio de percurso em água

Δh : Ondulação do terreno

Δh_m : Posição na ondulação do terreno

∂_j : Gradiente local de neurónio

η : Coeficiente de aprendizagem

θ : Peso de factor externo

λ : Comprimento de onda

μ : Coeficiente de ajuste de pesos

a_i : Parâmetros de calibração

b_i : Parâmetros de calibração

d : distância

d_v : Distância percorrida em vegetação

d_j : Valor desejado

d_s : Distância percorrida em água

E : soma dos erros quadráticos instantâneos

e_j : Erro num neurónio

f : função de ativação

h_{be} : Altura efetiva de estação base

h_m : Altura da estação móvel

K_{acl} : Fator corretivo, ruas radiais

K_{hp} : Fator corretivo, posição na ondulação de terreno

K_{mp} : Fator corretivo, água

K_{th} : Fator corretivo, ondulação do terreno

L_{diff} : Atenuação por difração

L_v : Atenuação por vegetação

v : Atividade de neurónio

v_k : Método Deygout

w_i : Peso sináptico

x_i : Valores de entrada

y : Valor de saída

Capítulo 1

Introdução

1.1 Enquadramento

O GSM-R (*Global System for Mobile Communications – Railway*) é uma norma internacional de comunicações móveis aplicado às linhas ferroviárias em todo o mundo. É um subsistema do ERTMS (*European Rail Traffic Management System*) e é utilizado para comunicação entre comboios e centros de controlo [1].

Nos meios de transporte ferroviários existe uma grande necessidade de garantir comunicações entre comboios e o GSM-R vem substituir os sistemas antigos de forma a garantir compatibilidade entre todas as linhas. O GSM-R é baseado no sistema GSM (*Global System for Mobile Communications*) por ser um sistema de grande sucesso e bastante eficiente em relação ao custo de instalação e manutenção.

O GSM-R fornece comunicações de voz e dados entre os vários colaboradores dos serviços ferroviários de forma a fornecer um serviço de transporte seguro e pontual. Na Europa o sistema opera na banda dos 876 até 880MHz na ligação ascendente e na banda dos 921 até 925MHz na ligação descendente.

A REFER Telecom - Serviços de Telecomunicações S.A, entidade participada a 100% pela REFER E.P., garante o suporte e operação das comunicações da rede ferroviária nacional e é responsável pelo planeamento, instalação e manutenção do sistema GSM-R em Portugal.

A rede piloto GSM-R foi instalada em 2012 na linha de Cascais, estando em fase de planeamento a cobertura rádio de mais linhas ferroviárias. O desenvolvimento da cobertura rádio GSM-R em Portugal tem sido acompanhado pelo ISEL desde a primeira hora, existindo um forte contributo científico nesta área, designadamente nos métodos utilizados para a estimação de cobertura rádio [2].

O cálculo da atenuação na propagação de sinal rádio é um dos passos fundamentais no projeto de qualquer rede sem fios. Na instalação de sistemas desta dimensão é necessário que as várias estações base forneçam a maior cobertura possível de forma a minimizar o número de estações base, diminuindo assim o custo de instalação global do sistema, e a interferência causada entre as várias estações.

A estimação de atenuação de sinal poderá ser feita através de uma abordagem determinística, ou seja, utilizar a modelação matemática dos mecanismos de propagação considerados para determinar o

comportamento do sinal, ou através de uma abordagem estatística. Devido ao elevado número de parâmetros a considerar é impossível calcular ao certo a atenuação de sinal em cenários reais com obstáculos, diferentes ambientes, terrenos irregulares entre outros fatores.

Para resolver este problema utilizam-se modelos de propagação que têm em conta os mecanismos de propagação de sinal em espaço livre e na presença de obstáculos e vários fatores corretivos obtidos através de análises estatísticas em diferentes cenários.

1.2 Motivação

No contexto do planeamento celular do sistema GSM-R em Portugal, foi desenvolvido um modelo de propagação baseado no modelo de Okumura-Hata [4] [5] para ambiente suburbano. Uma equipa do ISEL, em colaboração com a REFER Telecom tem vindo a estudar este modelo para a rede ferroviária nacional, tendo desenvolvidos algoritmos de otimização recorrendo a algoritmos genéticos para otimizar a estimativa da cobertura [6]. Com o presente trabalho, pretende-se encontrar uma alternativa ao trabalho proposto anteriormente, utilizando para o efeito redes neuronais.

As redes neuronais artificiais são modelos computacionais baseados no funcionamento do sistema nervoso central, em particular o cérebro, e são utilizados para estimação ou aproximação de uma função que depende de um elevado número de valores de entrada [7].

Uma Rede Neuronal tipicamente apresenta-se como um conjunto de neurónios ligados entre si que trabalham em paralelo para calcular valores de saída com base em valores de entrada e podem ser utilizados como máquinas de aprendizagem ou para reconhecimento de padrões, tal como o cérebro humano.

Um dos paradigmas de aprendizagem de redes neuronais é a aprendizagem supervisionada. Pretende-se utilizar como valores de entrada, informação que descreve as características de terreno das linhas ferroviárias, e ensinar uma rede neuronal a estimar a atenuação em qualquer ponto da linha tendo como base as medidas retiradas nessas mesmas linhas.

1.3 Objetivos

Este trabalho tem como objetivo propor uma alternativa aos métodos atualmente utilizados na estimação de cobertura rádio utilizando redes neuronais. Pretende-se explorar diferentes abordagens e comparar os resultados entre si para chegar a uma solução ótima para o problema em questão. Numa fase inicial pretende-se estudar cada um dos cenários considerados neste trabalho individualmente de forma a chegar a uma solução otimizada para cada um deles. Posteriormente pretende-se obter uma solução generalizada para todos os casos otimizando a estimação de cobertura rádio em todos os casos.

Na otimização de cada cenário pretende-se seguir duas abordagens distintas. Uma das abordagens propostas baseia-se no modelo de propagação de Okumura-Hata tentando otimizar os parâmetros de calibração deste modelo e assim obter uma solução mais aproximada do comportamento real do sinal no contexto das comunicações móveis ferroviárias. A segunda abordagem propõe uma abstração do modelo de propagação considerando apenas informação sobre o terreno para a estimação de cobertura rádio.

Na otimização generalizada pretende-se perceber as diferenças que existem nos vários cenários e criar um algoritmo, baseado em redes neurais, capaz de diferenciar as características dos vários pontos de cada cenário e chegar a uma solução de compromisso que otimize a estimação de cobertura rádio em todos os cenários.

Com base nos resultados obtidos nas várias experiências realizadas pretende-se comparar os vários resultados, incluindo os resultados obtidos através do modelo de propagação de Okumura-Hata e apresentar uma solução ótima para os casos particulares e para os casos gerais, ou seja, uma solução ótima para cada cenário e uma solução ótima geral para todos os cenários.

1.4 Estrutura do relatório

O presente relatório divide-se em seis capítulos, o capítulo dois descreve os vários cenários considerados para caso de estudo, descreve também todo o processo de recolha de medidas nas várias linhas ferroviárias consideradas neste trabalho explicando o modelo de propagação e os vários parâmetros de terreno e fatores corretivos considerados na estimação de cobertura rádio.

O terceiro capítulo começa por introduzir as redes neurais, explicando os conceitos teóricos e descrevendo o seu funcionamento desde o perceptrão até as redes complexas com várias camadas de neurónios. Descreve também os conceitos de uma rede neuronal baseada em aprendizagem competitiva que divide um conjunto de vetores em várias classes.

O quarto capítulo descreve a fase de implementação deste trabalho, explicando todo o processo de dimensionamento necessário de cada uma das redes. Descreve também a aplicação final implementada apresentada como solução final do problema da estimação de cobertura rádio em sistemas GSM-R.

O quinto capítulo apresenta os resultados das várias experiências realizadas, descritas no capítulo quatro, comparando os resultados obtidos com os resultados de trabalhos anteriores.

Finalmente, o último capítulo apresenta as conclusões finais resultantes do trabalho desenvolvido.

Propagação Rádio em Comunicações Ferroviárias

Como já foi demonstrado anteriormente pelo trabalho desenvolvido entre o ISEL e a REFERTelecom, a propagação rádio em ambientes ferroviários apresenta algumas características que levam a que os métodos normalmente utilizados no planeamento de cobertura rádio de redes de comunicações móveis públicas apresentem resultados que não se traduzem na máxima eficiência da rede projetada.

Na predição de cobertura rádio em ambientes ferroviários, o modelo de propagação Okumura-Hata tem conduzido a resultados bastante satisfatórios, conduzindo a erros reduzidos, quando complementado com fatores corretivos adequados ao tipo de ambiente [8]. Assim, apesar de ser objetivo deste trabalho substituir o modelo Okumura-Hata por uma rede neuronal que efetue a predição de cobertura rádio, importa apresentar este modelo, utilizado como referência. Por outro lado, os parâmetros de entrada do modelo, relacionados com a informação geográfica e do sistema rádio, serão utilizados pela rede neuronal, pelo que a sua definição neste contexto é igualmente importante.

Por outro lado, na análise de desempenho do algoritmo de predição desenvolvido, serão utilizados os dados resultantes de campanhas de medidas em diversas linhas, que serão utilizadas neste contexto como casos de estudo de referência.

Neste capítulo será apresentado em primeiro lugar o modelo de Okumura-Hata e todos os fatores corretivos e métodos adicionais utilizados na predição de cobertura rádio. Posteriormente apresentam-se as linhas de referência neste estudo, bem como as medidas realizadas nestes cenários. Finalmente, é apresentada a ferramenta de predição utilizada como base deste trabalho, e cuja informação resultante do processamento de informação geográfica irá ser a entrada do algoritmo desenvolvido.

2.1 Modelo de Propagação Okumura-Hata

O modelo de propagação de Okumura-Hata é um modelo desenvolvido com base no modelo de Okumura e é o modelo mais utilizado atualmente na estimação de cobertura rádio durante a fase de planeamento de uma rede móvel por produzir resultados bastante aceitáveis. As seguintes subsecções descrevem as especificações do modelo.

2.1.1 Cálculo de atenuação

O cálculo da atenuação de sinal é um dos passos fundamentais do planeamento de redes móveis. No cálculo da atenuação de um sinal rádio um dos possíveis modelos, e o considerado neste trabalho como referência, é o modelo de Okumura-Hata descrito em (1).

$$Lp = a1 + a2 * \log(f_{[MHz]}) + a3 * \log(h_{be}) + b1 * \log(d_{[km]}) + b2 * \log(h_{be[m]}) \\ * \log(d_{[km]}) - a(h_m) - \sum \text{fatores correctivos} \quad (1)$$

O modelo considera os efeitos físicos de dispersão do sinal rádio assim como alguns fatores corretivos. Devido à elevada complexidade na descrição dos mecanismos que afetam a propagação do sinal é impossível obter um resultado determinístico de atenuação de sinal com o poder computacional disponível atualmente. Por esse motivo são adicionados fatores corretivos baseados em várias medidas efetuadas para simplificar este cálculo.

$$a(h_m) = (1.1 \log(f_{[MHz]}) - 0.7) * h_m - 1.56 * \log(f_{[MHz]} + 0.8) \quad (2)$$

Em (2) está representada a correção sugerida pelo modelo para ambientes suburbanos, esta correção considera a altura do móvel e a frequência. No contexto deste estudo, apenas é considerada a frequência dos 900 MHz do GSM e uma altura do terminal móvel fixa de quatro metros que corresponde à altura da cabine rádio instalada na cabine do maquinista dos comboios.

$$\sum \text{fatores correctivos} = -L_{diff} - L_v + K_{mp} + K_{th} + K_{hp} + K_{acl} \quad (3)$$

Em que:

Lp : Atenuação [dB]

$a(h_m)$: Fator de correção que depende do ambiente

f : Frequência (900MHz)

d : Distância [km]

$h_{be[m]}$: Altura efetiva da estação base

h_m : Altura da estação móvel (4m)

Em (3) está representado o somatório dos vários fatores corretivos considerados por este modelo, esta correção considera a atenuação adicional por obstrução do sinal por obstáculos, passagem do sinal por terreno vegetativo, influência de água, ondulação do terreno e ruas radiais, a descrição detalhada de cada parâmetro encontra-se no capítulo seguinte.

Parâmetro	Valor
a1	69.55
a2	26.16
a3	-13.82
b1	44.9
b2	-6.55

Tabela 1 - Parâmetros de calibração do modelo.

Na tabela 1 apresentam-se os parâmetros de calibração do modelo de propagação. Estes valores variam consoante o ambiente de propagação considerado. Os valores apresentados são os definidos por omissão, no modelo original.

2.1.2 Altura efetiva

A altura efetiva corresponde à diferença das alturas da base da estação base e do ponto onde se encontra a antena do terminal. Em estudos anteriores [2] determinou-se que o cálculo da altura efetiva através do modelo ITU-R [9], produz resultados mais aproximados do valor real pois este parâmetro considera não só informação sobre a diferença das alturas do emissor e recetor mas também informação o terreno entre estes dois pontos. Neste trabalho a altura efetiva considerada é a especificada pelo modelo ITU-R.




Figura 1 - Altura efetiva (ITU-R).

No cálculo da altura efetiva através do modelo ITU-R é traçada uma reta entre a base da estação base e o local onde se encontra a estação móvel como ilustrado na figura 1. Ao longo da reta, da estação móvel até à estação base, são calculadas as diferenças entre a reta traçada e as cotas de terreno, a altura efetiva corresponde à soma da altura da estação base com a diferença média calculada.

Se o resultado da altura efetiva obtida for menor que um valor mínimo pré estabelecido então é considerado esse valor. No contexto deste trabalho é considerado o valor mínimo 1.

2.1.3 Atenuação por Difração

No cálculo de atenuação de sinal é necessário considerar a atenuação por difração devido a obstáculos. Neste modelo é considerado o método de Deygout [10], considerando o obstáculo principal de primeira ordem, o primeiro e o último obstáculo de segunda ordem entre as estações base e os vários pontos da linha como se pode observar na figura 2.

Este método considera os obstáculos obstruente como lâminas, dividindo o percurso em três partes, a primeira parte é a distância até ao primeiro obstáculo principal de segunda ordem, a segunda parte é a distância do primeiro obstáculo principal de segunda ordem até ao obstáculo principal de primeira ordem, e a terceira parte é a distância do obstáculo principal de primeira ordem até ao ultimo obstáculo principal de segunda ordem como demonstrado na figura 2.

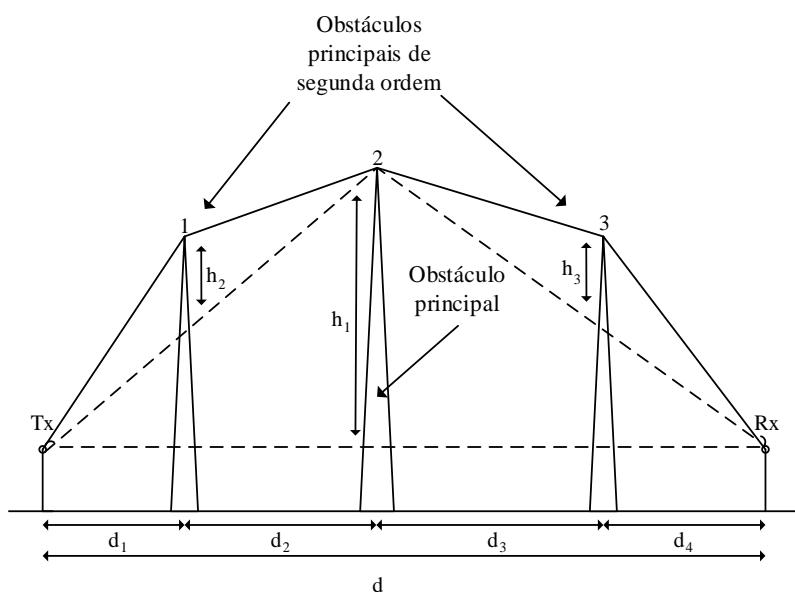


Figura 2 - Método de Deygout.

A expressão representada em (4) descreve a atenuação causada por cada obstáculo. Apenas é considerada esta atenuação se o valor do parâmetro v_k for superior a um determinado limiar pré estabelecido.

$$L_{diff_{[dB]}} = L_{diff1} + L_{diff2} + L_{diff3} \quad (4)$$

Como se pode observar em (4) a atenuação por difração no modelo em causa é calculada individualmente para cada um dos obstáculos, sendo a atenuação total por difração, a soma das três atenuações de cada um deles.

$$L_{diff_k}(v)_{[dB]} = \begin{cases} 0 & , \quad v_k \leq x_3 \\ x_1 + x_2 * \log\left(\sqrt{(v_k - 0.1)^2 + 1} + v_k - 0.1\right) & , \quad v_k > x_3 \end{cases} \quad (5)$$

Em (5) está representada a expressão matemática para cálculo da atenuação de cada obstáculo, apenas são considerados obstáculos cujo parâmetro v_k atinge um certo patamar definido na tabela 2.

$$v_k = h \sqrt{\frac{2d_{[m]}}{\lambda d_1 d_2}} \quad (6)$$

Os parâmetros v_k são calculados pela expressão matemática representada em (6). Os parâmetros x_1 , x_2 e x_3 estão indicados na tabela 2.

d_1 : Distância entre transmissor e obstáculo [m]

d_2 : Distância entre obstáculo e recetor [m]

λ : Comprimento de onda [m]

Parâmetro	Valor
x1	6.40
x2	20.00
x3	-0.70

Tabela 2 - Parâmetros de calibração do método de Deygout.

2.1.4 Atenuação pela presença de vegetação

Por vezes o sinal atravessa áreas com vegetação causando uma atenuação adicional no sinal que tem de ser contabilizada. No cálculo desta atenuação é considerado o modelo de Weissberger [11] ou modelo de decaimento exponencial de Weissberger, que é um modelo de propagação que estima a atenuação de sinal rádio devido à presença de uma ou mais árvores numa ligação rádio ponto a ponto.

Apesar deste modelo apenas ser especificado para distâncias em vegetação inferiores a 400 metros, o modelo apresentou-se como um modelo simples e produz bons resultados fazendo uma extrapolação para valores superiores.

$$Lv_{[dB]} = \begin{cases} v_1 * f_{[GHz]}^{0.284} * d_v[m] & , 0 \leq d_v \leq 14 \\ v_2 * f_{[GHz]}^{0.284} * d_v^{0.588} & , 14 \leq d_v \leq 400 \end{cases} \quad (7)$$

Em que:

d_v : Distância percorrida em vegetação [m]

Em (7) está representada a expressão matemática definida por este modelo, para valores superiores a 400 metros é considerada a segunda parcela da equação.

Na tabela 3 estão indicados os parâmetros de calibração especificados pelo modelo descrito neste capítulo.

Parâmetro	Valor
v_1	0.063
v_2	0.187

Tabela 3 - Parâmetros de calibração do modelo de Weissberger.

2.1.5 Influência de Água

Em planeamento rádio, um dos cenários mais problemáticos são áreas em que o sinal atravessa superfícies aquáticas. Nestes pontos observa-se uma descida significativa da atenuação devido à elevada refletividade da água. Esta descida da atenuação provoca um aumento de cobertura e nestes cenários.

Nos cenários estudados durante este trabalho, especialmente na linha de Cascais, existem pontos em que o sinal atravessa superfícies aquáticas, e a sua influência tem de ser contabilizada na estimação de cobertura. A influência da água é contabilizada pelo modelo de Okumura-Hata através do fator corretivo K_{mp} representado em (8).

$$K_{mp}(\beta)_{[dB]} = m_{11} * \beta^2 + m_{21} * \beta \quad (8)$$

d_s : Distância percorrida pelo sinal sobre um traçado com água [m]

O parâmetro β representa a relação entre a distância total percorrida e a distância percorrida na superfície aquática, como representado na figura 3. A tabela 4 indica os parâmetros de calibração deste fator corretivo. O parâmetro é calculado por:

$$\beta = \frac{d_s}{d}, \quad d \leq 30km$$




Figura 3 - Influência da água.

Parâmetro	Valor
m11	-8.00
m21	19.00
m12	7.80
m22	5.80

Tabela 4 - Parâmetros de calibração do fator corretivo K_{mp} .

2.1.6 Ondulação do terreno

Por vezes a superfície terrestre apresenta um relevo montanhoso e irregular, especialmente em zonas rurais, sendo necessário contabilizar a influência dessa irregularidade na estimação de cobertura rádio. O modelo descrito neste capítulo contabiliza essa influência através do fator corretivo K_{th} apresentado em (9).

$$K_{th}(\Delta h)_{[dB]} = u_1 * \log^2(\Delta h_{[m]}) + u_2 * \log(\Delta h_{[m]}) + u_3 \quad (9)$$




Figura 4 - Ondulação do terreno.

O fator corretivo determina a atenuação causada pela irregularidade do terreno através da diferença de alturas do ponto mais alto e o ponto mais baixo como demonstrado na figura 4. A tabela 5 indica os parâmetros de calibração deste fator corretivo.

Parâmetro	Valor
u1	-3.00
u2	-0.50
u3	4.50

Tabela 5 - Parâmetros de calibração do fator corretivo K_{th} .

2.1.7 Posição na ondulação do terreno

O fator corretivo descrito na secção anterior considera a ondulação do terreno no cálculo da atenuação de sinal. A presença de terreno ondulado trás a necessidade de considerar também a posição da estação móvel nessa mesma ondulação. Essa correção é feita através do fator corretivo K_{hp} calculado através de (10).

$$K_{hp}(\Delta h_m)_{[dB]} = p_1 * \log^2(\Delta h_{m[m]}) + p_2 * \log(\Delta h_{m[m]}) + p_3 \quad (10)$$

Como se pode verificar por (10) e pela figura 5, este fator corretivo é calculado através da distância entre a altura do ponto médio da ondulação do terreno e altura da posição onde se encontra a estação móvel.




Figura 5 - Posição na ondulação do terreno.

Na tabela 6 estão indicados os parâmetros de calibração considerados por este modelo no fator corretivo K_{hp} .

Parâmetro	Valor
p1	-2.00
p2	16.00
p3	12.00

Tabela 6 - Parâmetros de calibração do fator corretivo K_{hp} .

2.1.8 Correção por Orientação ou Ruas Radiais

A orientação das antenas emissoras em relação à estação móvel e a presença de ruas radiais tem influência na atenuação de sinal. O modelo de propagação descrito neste capítulo considera este efeito pelo fator corretivo K_{acl} que pode ser calculado através de (11).

$$K_{acl}(d)_{[dB]} = c_1 * \log(d_{[km]}) + c_2 \quad (11)$$

No contexto das redes neuronais este fator é redundante pois é função do logaritmo da distância que já é considerado anteriormente na expressão geral do modelo.

Parâmetro	Valor
c1	-2.70
c2	8.60

Tabela 7 - Parâmetros de calibração do fator corretivo K_{act} .

Na tabela 7 estão indicados os parâmetros de calibração do fator corretivo K_{act} considerados por este modelo de propagação.

2.2 Casos de estudo e medidas rádio

No âmbito deste trabalho são consideradas três linhas ferroviárias para caso de estudo: A linha de Évora, Algarve e Cascais. As três linhas estão situadas em zonas muito distintas e por isso é esperado que um sinal rádio se comporte de forma diferente em cada uma delas. Isto motiva o estudo individual de cada uma das linhas e a análise à propagação de sinal em cada um destes ambientes. As seguintes subsecções descrevem com maior detalhe cada uma das linhas.

A escolha das linhas para casos de estudo deveu-se à disponibilidade de medidas de cobertura rádio realizadas pela REFERTelecom nestas linhas, o que permitirá desenvolver os algoritmos de aprendizagem e validar devidamente os resultados obtidos.

2.2.1 Linha de Évora

A linha de Évora é a linha ferroviária que faz a ligação da linha do Alentejo, em Casa Branca, com a cidade de Évora. Durante a campanha de medidas considerou-se também um troço da linha do Alentejo entre as estações de Casa Branca e Vendas Novas, tendo o troço uma extensão de 60 km.

O troço de linha considerado está representado na figura 6 e é caracterizado por zonas abertas e ambiente rural por se tratar de uma área pouco habitada.



Figura 6 - Linha ferroviária de Évora.

Durante a campanha de medidas foram feitas três viagens, representadas na figura 6, percorrendo toda a linha. Em cada viagem colocaram-se três estações base de teste ao longo da linha em frequências diferentes e foi medido o nível de sinal recebido de cada uma delas em cada ponto da linha.




Figura 7 - Viagens de teste na linha de Évora.

Na figura 8 está representado o nível de sinal medido, em três frequências, ao longo da linha de Évora na primeira viagem de teste. Pela figura podem-se observar alguns fenómenos que afetam as medidas recolhidas. Um dos fenómenos existentes é a variação da potência medida do sinal na presença de sinais fortes em bandas adjacentes. Esta perturbação nas medidas é devida principalmente à gama dinâmica do amplificador de entrada do equipamento de medidas, associada à seletividade dos filtros digitais utilizados no pós-processamento.

Pela figura 8 observa-se também que existe uma saturação por volta dos -62dBm provocada pela dessensibilização do amplificador de entrada do aparelho de medida, devido à gama dinâmica. Os valores saturados e os valores abaixo do patamar de ruído são removidos e não são considerados durante o estudo.

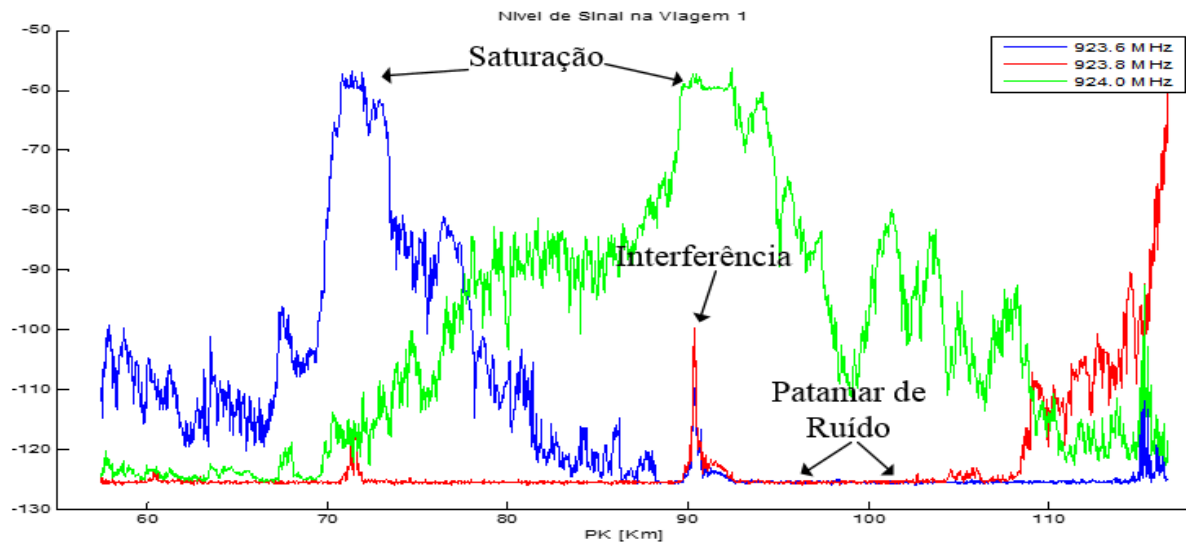


Figura 8 - Medidas obtidas na 1ª viagem de teste na linha de Évora.

2.2.2 Linha de Cascais

A linha de Cascais foi a linha selecionada para a implementação do projeto piloto GSM-R em Portugal sendo a primeira linha ferroviária com cobertura móvel de uma rede digital GSM-R. O sistema é constituído por cinco estações base e um repetidor e tem atribuído quatro frequências. Cada estação base é constituída por duas antenas diretivas direcionadas para cada uma das direções da linha.




Figura 9 - Estação base GSM-R da linha de Cascais.

A figura 9 representa a direção de propagação dos sinais f1 e f2 na linha. Cada um dos sinais está direcionado para lados opostos da linha sendo apenas consideradas medidas de f1 à esquerda da estação base, e medidas de f2 à direita da estação base.

Devido a uma sobreposição entre sinais na mesma frequência emitidas pelo repetidor e a estação base vizinha, as medidas do repetidor não são consideradas neste trabalho por apenas existir um número limitado de medidas válidas.

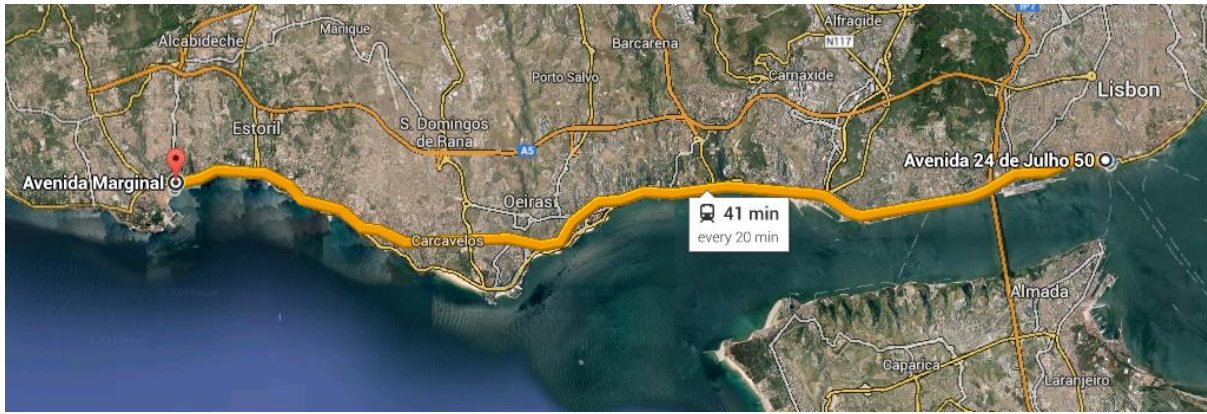


Figura 10 - Linha ferroviária de Cascais.

Na figura 10 está representada a linha ferroviária de Cascais, a linha tem uma extensão total de 26 km e caracteriza-se por um ambiente suburbano com uma forte influência de água, pois a linha encontra-se à beira-mar em quase todo o seu percurso.

Estação Base	Frequência [MHz]
SantosA (repetidor)	921.2
AlcantaraA	921.2
AlcantaraB	921.2
PedrouçosA	922.0
PedrouçosB	922.0
PaçoArcosA	922.8
PaçoArcosB	922.8
PK16.865A	923.6
PK16.865B	921.2
SãoJoãoA	922.0
SãoJoãoB	922.0

Tabela 8 – Estações base na linha de Cascais e respetivas frequências.

Na tabela 8 estão indicadas as frequências das cinco estações base e a do repetidor, cada estação base tem duas antenas que operam na mesma frequência ou em frequências diferentes, no caso da estação base PK16.864.

2.2.3 Linha do Algarve

Na figura 11 está representada um troço da linha ferroviária do Algarve onde foram retiradas medidas de teste. O troço de linha tem o comprimento de 60 km e é caracterizada pela presença de água em

alguns pontos da linha e pela presença de muitos obstáculos entre as estações base e os vários pontos da linha.



Figura 11 - Linha ferroviária do Algarve.

Assim como na linha de Évora, durante a campanha de medidas foram feitas várias viagens de teste colocando estações bases em frequências diferentes ao longo da linha e medido o nível de sinal recebido em todos os pontos dessas mesmas estações base. As viagens efetuadas nesta linha estão representadas na figura 12.

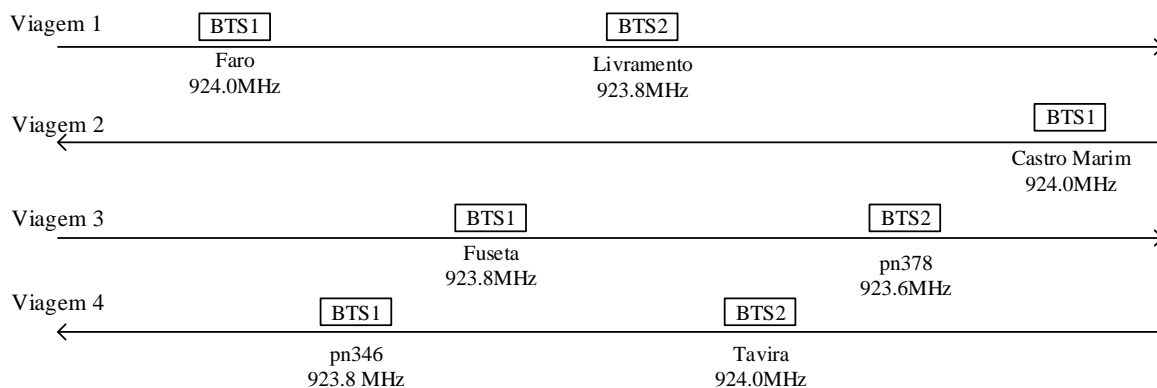


Figura 12 - Viagens de teste na linha do Algarve.

Foram efetuadas quatro viagens de teste colocando estações base em sete locais distintos ao longo da linha como se pode observar pela figura 12.

2.2.4 Resumo das Medidas

A tabela 9 indica a quantidade de estações base e o número de medidas que foram recolhidas durante as várias campanhas.

Linha	Número de estações base	Número total de amostras	Número de amostras validas
Évora	8	15573	5260
Cascais	5	5178	3156
Algarve	7	14285	14285

Tabela 9 - Estatísticas das medidas retiradas das três linhas.

No âmbito de treinar uma rede neuronal no contexto deste trabalho é necessário não considerar medidas saturadas ou abaixo do patamar de ruído pois não refletem o comportamento real do sinal mas sim as limitações do equipamento de medida. Para uma estimação de sinal mais realista as medidas inválidas são eliminadas e não são apresentadas às várias redes neuronais criadas durante este trabalho.

2.2.5 Ferramenta de Perdição de Sinal

Para poder estimar o nível de sinal de uma rede GSM-R num determinado ponto de uma linha ferroviária é necessário considerar informação sobre o terreno presente entre a estação base e a estação móvel.

No âmbito da cooperação entre a REFER-Telecom e o ISEL foi desenvolvido a aplicação RailWave [12]. Esta aplicação tem como objetivo o planeamento de redes GSM-R através da estimação do nível de sinal em linhas ferroviárias utilizando o modelo de propagação de Okumura-Hata. A aplicação permite também, através de ficheiros de informação sobre o terreno, gerar os vários parâmetros especificados pelo modelo de Okumura-Hata assim como os respetivos fatores corretivos.

Para treinar uma rede neuronal através da aprendizagem supervisionada é necessário um conjunto de valores de entrada e os respetivos valores de saída esperados. Os vários parâmetros de terreno exportados através desta aplicação não coincidem geograficamente com os valores medidos durante a campanha de medidas e de forma a obter um valor medido e os respetivos parâmetros de terreno em cada ponto das várias linhas, a aplicação faz uma interpolação dos valores medidos de forma a obter para cada ponto, um valor medido e os vários parâmetros de terreno.

A aplicação tem ainda em conta o desvanecimento rápido do sinal aplicando o modelo de Lee [13] às medidas recolhidas de forma a obter um valor médio de sinal em todos os pontos. Os vários parâmetros de terreno disponíveis e utilizados neste trabalho são descritos na secção anterior assim como os respetivos fatores corretivos.

Capítulo 3

Redes Neurais

As redes neuronais têm vindo a ser utilizadas em várias aplicações, tais como, aproximação de funções, classificação de vetores, processamento de dados, robótica entre vários outros. No âmbito deste trabalho pretende-se explorar a vertente de aproximação de funções, ou seja, dado um conjunto de parâmetros à entrada, obter um valor correspondente na saída em função dos parâmetros de entrada.

Para a implementação de uma aplicação deste tipo é necessário abordar alguns conceitos teóricos sobre o seu funcionamento e perceber as várias fases na implementação de uma aplicação em redes neuronais. Este capítulo explica o funcionamento de uma rede neuronal começando pelo elemento mais básico, um neurónio, e em seguida explica o funcionamento de uma rede mais complexa constituída por vários neurónios que processam informação em paralelo para atingir um dado objetivo.

3.1 Introdução às Redes Neurais

Uma rede neuronal tenta modelar o funcionamento do cérebro humano, consistindo numa estrutura organizada de neurónios que processam informação de uma forma altamente paralela e distribuída. Assim como o cérebro humano, uma rede neuronal tem a capacidade de aprender à medida que recebe informação.

Uma rede neuronal é constituída por várias camadas de neurónios ligadas entre si, cada neurónio representa um nó da rede e é definido por um conjunto de ligações sinápticas, por um limiar aplicado externamente, e por uma função de ativação. Cada ligação sináptica tem um peso associado, e para cada ligação é multiplicado o valor à entrada pelo respetivo peso. A soma de todas as ligações representa o nível de atividade do neurónio que entra na função de ativação. Presente um vetor de valores à entrada da rede, e atribuídos os pesos a cada ligação entre os valores externos e as entradas de um neurónio, ou entre as saídas dos neurónios precedentes e as entradas dos neurónios seguintes é produzido um valor na saída.

Essencialmente, numa rede neuronal existem três fases: fase de inicialização, fase de treino ou aprendizagem, e fase de teste. Durante a fase de inicialização são definidos os valores dos pesos referentes a cada ligação sináptica de cada neurónio, tipicamente estes valores são gerados aleatoriamente dentro dum dado intervalo. Durante a fase de aprendizagem é apresentado à rede um conjunto de amostras de treino, e para cada uma destas amostras a rede altera o valor dos pesos consoante um algoritmo de aprendizagem, até que a rede convirja (ver mais adiante). Na fase de teste

é apresentado à rede um conjunto de amostras de teste, e são calculados os valores de saída em função dos valores de entrada sem alterar o valor dos pesos.

Existem três paradigmas de aprendizagem em redes neurais, a aprendizagem supervisionada, a aprendizagem não supervisionada e a aprendizagem por reforço. Nesta dissertação é explorado o paradigma de aprendizagem supervisionada. Esta aprendizagem consiste em treinar uma rede neuronal com um conjunto de amostras de valores de entrada e o conjunto dos respectivos valores de saída correspondentes. Assim, após a fase de aprendizagem a rede é capaz de representar os valores de saída em função do conjunto de valores de entrada.

3.2 Modelo de um neurónio

Na figura 13 está representado um dos modelos possíveis para um neurónio, o perceptrão. O perceptrão é um algoritmo de classificação supervisionada que atribui a um vetor de entrada uma de duas classes, desde que os exemplos de treino sejam linearmente separáveis.




Figura 13 - Modelo de um neurónio.

$$v = -1 * \theta + \sum_{i=1}^n x_i * w_i \quad (12)$$

$$y = f(v) \quad (13)$$

A variável v , representado em (12), representa o nível de atividade de um neurónio, e é calculado pelo somatório de $-1, x_1, x_2, \dots, x_n$ multiplicado por $\theta, w_1, w_2, \dots, w_n$. A variável y , representada em (13), é o valor de saída do neurónio, calculado através da função de ativação f , usando como valor de entrada o resultado do somatório obtido em (12).

As variáveis x_1, x_2, \dots, x_n representam os vários valores de entrada e a variável y representa o valor de saída. As variáveis $\theta, w_1, w_2, \dots, w_n$ representam os pesos sinápticos do perceptrão, sendo que estes determinam a influência do valor de entrada correspondente na saída v . A variável θ é o peso de um fator externo que serve para ajustar o neurónio de forma a produzir um deslocamento à saída. A

função f representa a função de ativação do neurónio, isto é, que permite separar os resultados na saída em duas classes.

Quando se constroem redes de perceptrões por razões que se prendem pela forma como a rede aprende (ver mais adiante), esta função tem de ser contínua em todos os pontos. Os valores dos pesos são aleatoriamente gerados na iniciação do neurónio e ajustados ao longo da fase de treino em função da diferença entre o valor esperado na saída e o valor produzido pela rede (erro).

3.3 Funções de Ativação

Em redes neuronais, a função de ativação determina o valor de saída de um neurónio em função da sua atividade calculada através do somatório dos valores de entrada multiplicados pelos respetivos pesos. Na figura 14 estão representadas três possíveis funções de ativação: a função linear, função sigmoide e função tangente hiperbólica.

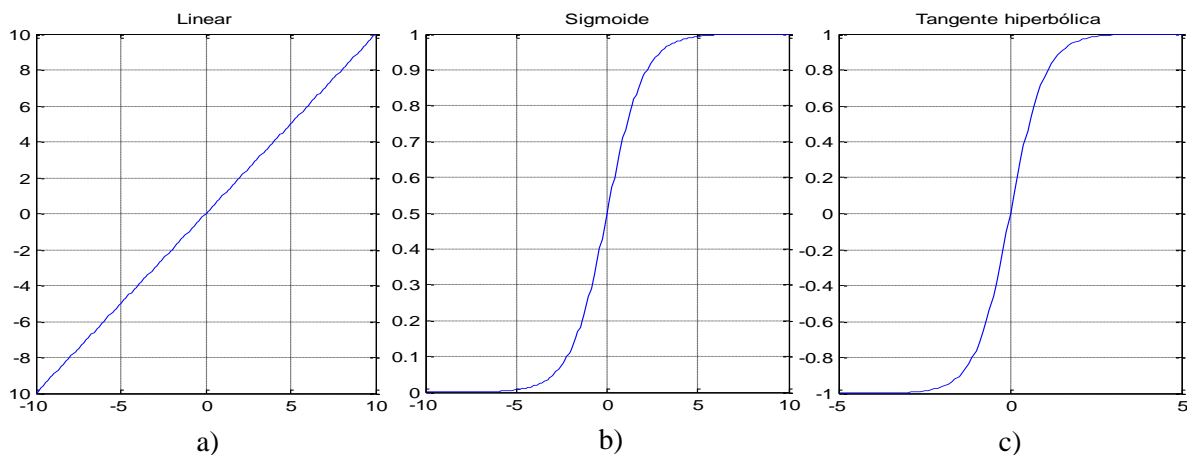


Figura 14 - Funções de ativação.

A função de ativação linear representada na figura 14 a) é uma função puramente linear dada por $y = kx + b$, em que k é o gradiente e b é o deslocamento. Esta função é pouco utilizada pois não é normalizável e torna a fase de aprendizagem bastante instável porque pode atingir valores de saída bastante elevados. A função sigmoide, representada na figura 14 b), é dada por $y = \frac{1}{1+e^{-x}}$ e varia entre os valores 0 e 1 e é maioritariamente utilizada em aprendizagem não supervisionada. A função tangente hiperbólica, representada na figura 14 c), é dada por $y = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ e varia entre os valores -1 e 1 e é maioritariamente utilizada em aprendizagem supervisionada.

3.4 Algoritmo de Aprendizagem

O processo de aprendizagem de uma rede neuronal consiste em adaptar os pesos sinápticos e os limiares de cada neurónio, a cada iteração, de forma a obter um valor de saída o mais aproximado possível do valor esperado.

No paradigma da aprendizagem supervisionada, que consiste em treinar uma rede neuronal com um conjunto de exemplos de treino, a rede adapta-se de forma a conseguir aproximar-se a uma função que represente os valores de saída em função dos valores de entrada.

A expressão representada em (14) representa a função de transferência da rede obtida através de (12) e (13) apresentadas na secção 3.2. A cada iteração é calculado o valor de y em função dos pesos e dos valores de entrada e durante a fase de aprendizagem o valor de y obtido é comparado com o valor esperado e é calculado o erro.

$$y = f(x_0 * \Theta + \sum_{i=1}^n x_i * w_i) \quad (14)$$

Conforme o erro obtido é necessário ajustar os valores dos pesos com o objetivo de reduzir o erro na amostra seguinte. Nesse intuito os novos pesos são calculados através de (15).

$$w_i(n + 1) = w_i(n) + \eta(d(n) - y(n)) * x_i(n) \quad (15)$$

Em que:

η : coeficiente de aprendizagem

d : valor esperado

n : número de amostra

w : peso

i : neurónio

O nível de ajuste dos pesos na fase de aprendizagem é determinado pelo fator de aprendizagem η . Se o valor de η for demasiado elevado os pesos sofrem uma elevada variação o que torna a rede instável. Se o valor de η for demasiado pequeno o valor dos pesos variam muito pouco o que provoca uma aprendizagem lenta precisando de um elevado número de iterações. Por estes motivos e para que uma rede seja eficiente na sua aprendizagem é necessário encontrar um valor ótimo de η .

Para uma maior eficiência, este fator pode ser adaptativo e variar ao longo do tempo para uma aprendizagem mais rápida, ou seja, se o erro diminuiu em relação à iteração anterior, aumenta-se o valor de η , se o erro aumentou, diminui-se o valor de η .

3.5 Rede Neuronal Multicamada

Nas secções anteriores foi descrito o funcionamento de um perceptrão que é capaz de classificar valores de entrada linearmente separáveis em uma de duas classes utilizando o método da aprendizagem supervisionada. Para a utilização de redes neuronais em aplicações mais complexas, como aproximação de funções, é necessário considerar uma rede com vários neurónios interligados entre si.

Uma rede neuronal multicamada consiste num conjunto de neurónios em série em que os valores de saída produzidos por uma camada são passados à camada seguinte como valores de entrada e assim

sucessivamente até à última camada. Esta designa-se camada de saída, onde são produzidos os valores de saída da rede. Cada camada é constituída por vários neurónios que processam a informação em paralelo.

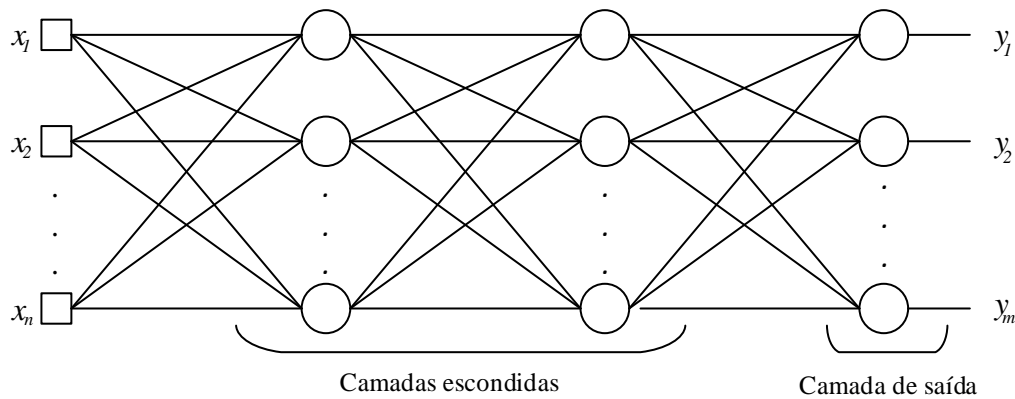


Figura 15 - Rede Neuronal Multicamada.

Na figura 15 está representada uma rede neuronal constituída por três camadas, n valores de entrada e m valores de saída. As camadas intermédias designam-se de camadas escondidas

Após a inicialização e gerados os valores dos pesos, a rede está preparada para iniciar a aprendizagem. Para isto é necessário um conjunto de valores de entrada e os respetivos valores esperados na saída (exemplos) para a rede ser treinada. Durante a aprendizagem, a rede vai ajustando os pesos à medida que recebe os valores de entrada e saída, e após várias iterações a rede converge.

Considera-se que a rede convergiu quando a soma dos erros quadráticos médios dos neurónios da camada de saída está abaixo de um patamar pré-estabelecido. O erro quadrático médio é calculado através de (16),(17) e (18) em que, após uma iteração, é calculado os erros de cada neurónio de saída, são somados os quadrados desses erros e é feito a média obtendo o valor de mse .

$$e_j(n) = d_j(n) - y_j(n) \quad (16)$$

$$E(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (17)$$

$$mse = \frac{1}{N} \sum_{n=1}^N E(n) \quad (18)$$

Em que:

e_j : erro do neurónio j , diferença entre valor desejado (d_j) e o valor obtido (y_j).

E : soma dos erros quadráticos instantâneos dos neurónios da camada de saída.

mse : erro quadrático médio.

n : número de amostra.

N : número total de amostras.

3.6 Algoritmo de Retro Propagação

Durante a fase de aprendizagem é necessário ajustar os valores dos pesos em cada iteração. Numa rede multicamada apenas se conhece os erros dos neurónios da camada de saída. Torna-se portanto necessário propagar o erro às restantes camadas de forma a poderem ser ajustados todos os pesos da rede.




Figura 16 - Método do gradiente descendente.

A figura 16 ilustra a variação da soma dos erros quadráticos instantâneos dos neurónios da camada de saída em função da variação dos seus pesos. Na fase de aprendizagem pretende-se obter os pesos que minimizem este erro, ou seja, pretende-se obter o mínimo desta função quadrática.

O algoritmo de retro propagação utiliza o gradiente local dos neurónios, representado em (19) para calcular o ajustamento dos pesos em cada iteração de forma a aproximar-se do ponto ótimo.

$$\Delta w_{ij}(n) = -\eta \frac{\partial E(n)}{\partial w_{ij}(n)} \tag{19}$$

Em que:

i: neurónio anterior

j: neurónio

Através da regra de Chain deduz-se que,

$$\frac{\partial E(n)}{\partial w_{ij}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ij}(n)} = -e_j(n) f'(v_j(n)) y_i(n) \tag{20}$$

Seja $\partial_j(n)$ o gradiente local do neurónio *j*,

$$\partial_j(n) = -\frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) f'(v_j(n)) \tag{21}$$

Sendo que,

$$\Delta w_{ij}(n) = \eta * \partial_j(n) * y_i(n) \tag{22}$$

$$\begin{cases} \partial_j(n) = f'(v_j(n)) * e_j(n) & \text{se } j \text{ for um neurónio da camada de saída} \\ \partial_j(n) = f'(v_j(n)) * \sum_k \partial_k(n) w_{jk} & \text{se } j \text{ for um neurónio da camada escondida} \end{cases} \quad (23)$$

Em que:

k = neurónios da camada seguinte

f é uma função contínua em todos os pontos

Por (22) e (23) é calculado o gradiente local de cada neurónio e o ajustamento dos pesos para a próxima iteração propagando o erro da camada de saída até à primeira camada.

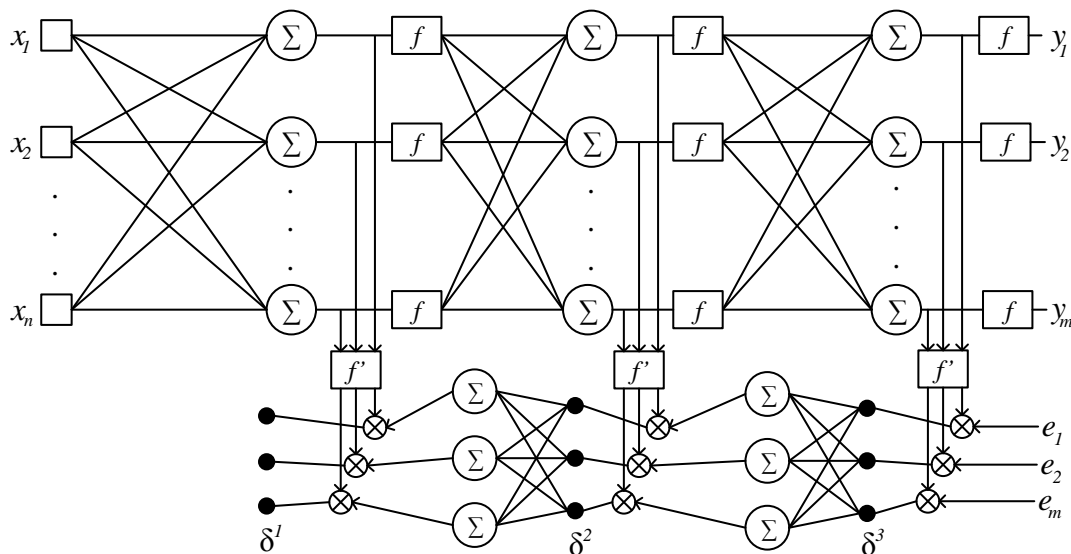


Figura 17 - Algoritmo de Retro Propagação.

A figura 17 ilustra graficamente o cálculo do gradiente local, de cada neurónio, usando o algoritmo de retro propagação. Para cada conjunto de valores de entrada, a rede calcula os valores de saída, o erro e o gradiente local dos neurónios desde a camada de saída até à primeira camada. De seguida, calcula os novos valores dos pesos e o novo valor do coeficiente de aprendizagem e passa à amostra seguinte. Este processo é repetido até que o erro quadrático médio seja inferior ao valor definido inicialmente.

3.6.1 Algoritmo de Retro Propagação de Levenberg-Marquardt

O algoritmo de Retro Propagação de Levenberg-Marquardt foi desenvolvido para otimizar o processo de aprendizagem de uma rede neuronal [14][15]. O algoritmo baseia-se no método do gradiente descendente e no método de Quasi-Newton usado para determinar zeros, máximos ou mínimos de funções [16].

Este algoritmo é o método de aprendizagem recomendado para treinar redes neuronais supervisionadas e é o algoritmo de aprendizagem mais rápido pois não precisa de calcular a matriz Hessiana que contém as derivadas parciais. A matriz Hessiana pode ser aproximada por (24).

$$H = J^t J \quad (24)$$

Em que J é a matriz jacobiana que contém as derivadas de primeira ordem da matriz dos erros em relação aos pesos. O gradiente pode ser aproximado por (25).

$$g = J^t e \quad (25)$$

Assim os novos valores dos pesos são calculados pela expressão representada em (26).

$$w_{n+1} = w_n - [J^t J + \mu I]^{-1} J^t e \quad (26)$$

Sendo que μ é o coeficiente de aprendizagem que controla a variação dos pesos.

3.7 Aprendizagem Competitiva

Uma rede neuronal competitiva é constituída por apenas uma camada, designada por camada competitiva, e baseia-se numa competição entre todos os neurónios em que apenas um se mantém ativo em cada instante. Numa rede deste tipo todos os neurónios têm uma estrutura semelhante à exceção dos seus pesos sinápticos inicializados aleatoriamente.

A cada iteração, cada neurónio compara a distância euclidiana entre os valores de entrada e os valores dos pesos, o neurónio que com a menor distância, ou seja, com a maior semelhança entre o vetor dos pesos e o vetor de entrada, ganha a competição e é ativado. O resultado é propagado para os restantes neurónios inibindo-os de serem ativados.

Esta aprendizagem caracteriza-se por ser uma aprendizagem não supervisionada e destina-se a classificar um conjunto de vetores em diferentes classes, cada neurónio representa uma classe e quando é ativado significa que o vetor presente à entrada nessa iteração é pertencente à classes que esse neurónio representa.

Durante a fase de aprendizagem, a cada iteração, o neurónio que é ativado por um determinado vetor de entrada ajusta os seus pesos de forma a reduzir ainda mais a distância euclidiana entre o vetor dos pesos e o vetor de entrada. A variação dos pesos é calculada através de (27).

$$\Delta w_{ij} = \begin{cases} \eta(x_i - w_{ij}) & \text{se } j \text{ for ativado} \\ 0 & \text{se } j \text{ não for ativado} \end{cases} \quad (27)$$

Em que:

j : neurónio

i : valor de entrada

A soma de todos os pesos sinápticos de cada neurónio é constante ao longo do processo de aprendizagem.




Figura 18 - Rede Neuronal Competitiva

Na figura 18 está representada uma rede competitiva, cada neurónio é ligado a todos os valores de entrada e é ligado a todos os outros neurónios de forma a quando vários neurónios são ativados, apenas o que tem a menor distância euclidiana, entre o vetor dos pesos e o vetor de entrada, se mantém ativo.




Figura 19 - Exemplo de classificação

A figura 19 representa um exemplo de classificação através de uma rede competitiva com um vetor de entrada de duas dimensões com três neurónios. A rede agrupa os vetores de entrada em *clusters* como se pode observar na figura.

Capítulo 4

Implementação

Este trabalho tem como objetivo propor algoritmos, baseados em redes neurais, para propor uma alternativa à estimação de cobertura rádio nos sistemas de comunicações moveis em ambiente ferroviário. Com esse objetivo foram criadas várias redes neurais, seguindo abordagens diferentes, e comparadas entre si para se obter uma solução ótima na estimação de sinal.

No capítulo 2 foram apresentadas três linhas ferroviárias, localizadas em regiões distintas, disponíveis para casos de estudo neste trabalho. Pretende-se, treinando uma rede neuronal para cada uma das linhas, obter uma solução ótima que minimize o erro na estimação de sinal em cada um dos diferentes cenários. Posteriormente pretende-se treinar uma rede neuronal generalizada para os três casos de estudo para estimar a cobertura de sinal em qualquer um dos cenários apresentados.

Este capítulo descreve os vários passos do dimensionamento das várias redes, assim como o pré e pós processamento efetuado e a parametrização considerada.

4.1 Considerações prévias

No paradigma da aprendizagem supervisionada o conjunto de dados é dividido em três grupos, o conjunto de amostras de treino, o conjunto de amostras de validação e o conjunto de amostras de teste. Com base em valores típicos, na tabela 10 está definida a divisão das amostras consideradas durante este trabalho. Cada amostra representa um ponto de uma dada linha ferroviária e é constituída pelos vários parâmetros de terreno, descritos no capítulo 2, e pelo respetivo valor medido durante a campanha de medidas efetuada pela REFER-Telecom.

Conjunto de amostras	Percentagem de amostras
Treino	60%
Validação	20%
Teste	20%

Tabela 10 - Divisão de amostras.

4.1.1 Conjunto de Amostras de Treino

O conjunto de amostras de treino define-se por ser o conjunto de valores de entrada e seus respetivos valores esperados de saída apresentados à rede durante a fase de aprendizagem, em que, com base na

diferença entre o valor obtido e o valor esperado, são alterados os valores dos pesos das várias ligações sinápticas da rede para minimizar o erro na iteração seguinte.

Em redes neuronais uma época define-se pelo conjunto total de amostras de treino apresentadas à rede, durante a fase de aprendizagem, numa dada iteração.

4.1.2 Conjunto de Amostras de Validação

O conjunto de amostras de validação é utilizado durante a fase de treino para validar a alteração aos pesos a cada época. Após cada época é apresentado à rede o conjunto de amostras de validação, sem alterar o valor dos pesos, e com base na diferença entre o valor obtido e o valor esperado é verificado se o erro diminuiu em relação à época anterior sobre esse conjunto de amostras. Este conjunto de amostras serve para evitar que a rede fique demasiado específica para o conjunto de amostras de treino.

4.1.3 Conjunto de Amostras de Teste

O conjunto de amostras de teste não é apresentado à rede durante a fase de aprendizagem. Após a rede ser treinada, e definidos os valores ótimos dos pesos, é testada a rede com o conjunto de amostras de teste e verificado o erro. O erro obtido neste conjunto de amostras é o considerado como medida de desempenho da rede e utilizado como referência de comparação por não ter sido utilizado na fase de aprendizagem.

4.2 Parâmetros de Entrada

Os valores de entrada considerados neste trabalho, apresentados na tabela 11, são os parâmetros de terreno definidos pelo modelo descrito no capítulo 2.

Parâmetro	Descrição
d	Distância
h_{be}	Altura efetiva
v_1	Obstáculo principal
v_2	Primeiro obstáculo
v_3	Ultimo obstáculo
d_v	Distância percorrida em vegetação
β	Rácio de distância percorrida em água
Δh	Ondulação do terreno
Δh_m	Posição na ondulação do terreno

Tabela 11 - Parâmetros de entrada.

4.3 Processamento adicional

Na tabela 11 estão representados os vários parâmetros de entrada considerados para o treino das várias redes. Os vários parâmetros têm métricas diferentes sendo que o domínio de valores possíveis de cada parâmetro é diferente. Dado que uma rede neuronal inicialize os seus pesos aleatoriamente é necessário que todos os valores de entrada estejam definidos dentro do mesmo intervalo. Para isso é necessário efetuar um pré e pós processamento como ilustrado na figura 20.




Figura 20 - Processamento adicional.

4.3.1 Normalização

Para que todos os valores de entrada estejam dentro do mesmo intervalo é necessário normalizar os parâmetros de entrada e os valores de saída. A normalização é obtida através de (28).

$$X_{normalizado} = a + \frac{(X - X_{min})(b - a)}{X_{max} - X_{min}} \quad (28)$$

Em que:

a : limite inferior.

b : limite superior.

Durante o pré processamento os vários parâmetros são normalizados utilizando a expressão representada em (28) e no pós processamento, o valor à saída da rede sofre a operação inversa que pode ser calculada trocando o valor de X_{min} pelo valor de a e o valor de X_{max} pelo valor de b .

4.4 Função de Ativação

A função de ativação utilizada para os vários neurónios das diferentes redes treinadas é a da tangente hiperbólica, representada na figura 21, por se tratar de uma aprendizagem supervisionada.




Figura 21 - Função de ativação.

A tangente hiperbólica é uma função contínua em todos os pontos com duas assíntotas no eixo das ordenadas. No âmbito do treino de uma rede neuronal, para uma maior eficiência no tempo de treino, os valores de saída são normalizados entre o intervalo -0.98 e 0.98 porque a tangente hiperbólica só atinge o seu valor máximo no infinito e assim as amostras de treino com o valor esperado muito próximo do valor máximo nunca chegam a atingir o valor desejado.

4.5 Algoritmo de Aprendizagem

O algoritmo de aprendizagem utilizado na fase de treino das várias redes foi o algoritmo de retro propagação de Levenberg-Marquardt pois revelou ser o mais eficiente e preciso em redes neuronais com aprendizagem supervisionada.

4.5.1 Parametrização do algoritmo de aprendizagem

O coeficiente de aprendizagem do algoritmo de retro propagação de Levenberg-Marquardt, designado por μ , define a variação dos pesos durante a fase de aprendizagem. Na tabela 12 está indicada a parametrização de μ considerada para as várias redes. Foram testados vários valores de incremento e decremento e verificou-se que para a aplicação de redes neuronais na estimação de sinal rádio, devido à sua elevada complexidade, um valor reduzido de μ produz uma maior consistência na fase de treino, ou seja, treinando a mesma rede várias vezes produz aproximadamente o mesmo erro.

μ inicial	10
Incremento de μ	1.1
Decremento de μ	0.9
μ máximo	1e+10

Tabela 12 - Parametrização do coeficiente de aprendizagem.

4.6 Critérios de Paragem

A fase de aprendizagem de uma rede neuronal termina quando, após várias épocas, a rede converge. Por norma, considera-se que uma rede neuronal convergiu quando atinge um determinado valor de erro pré estabelecido. Para obter uma maior eficiência, e minimizar o tempo de treino, existem outros critérios considerados na convergência da rede. As seguintes subsecções descrevem os vários critérios de paragem considerados em que basta um se aplicar para a fase de aprendizagem ser terminada.

4.6.1 Número Máximo de Épocas

Determinou-se que com o conjunto de dados disponíveis neste trabalho, a partir de 250 épocas não existe nenhum ganho significativo no erro obtido e por isso esse valor é considerado no critério de paragem, ou seja, ao fim de 250 épocas a fase de aprendizagem é terminada. Na figura 22 está representada a evolução do erro quadrático médio durante duas fases de treino realizadas neste trabalho. Observa-se que as redes convergiram dentro do número de épocas estipulado.

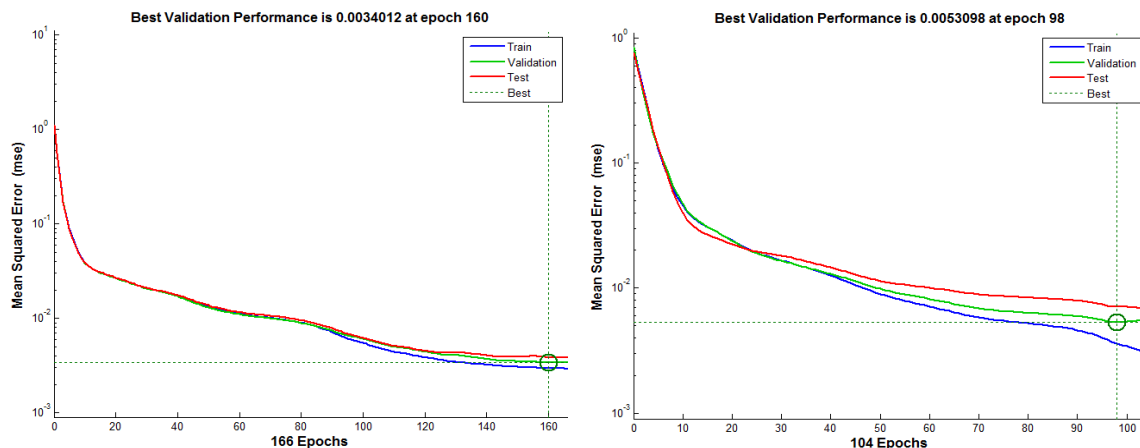


Figura 22 - Evolução do erro durante a fase de treino.

4.6.2 Número Máximo de Validações Falhadas

Um dos problemas em redes neurais é a perda do poder de generalização, ou seja, a rede adapta-se demasiado ao conjunto de amostras de treino que resulta num aumento exponencial do erro nas amostras de teste. Para evitar este fenómeno existe um conjunto de amostras de validação em que é verificado o erro sobre este conjunto após cada época e se o erro aumentou em relação à época anterior, considera-se que houve uma validação falhada.

Quando uma validação falha, ou seja, o erro quadrático médio no conjunto de validação aumenta, são consideradas ainda 6 épocas. Se nessas 6 épocas o erro voltar a diminuir, então o treino continua, se nas 6 épocas seguintes o erro for superior à ultima validação positiva então as 6 épocas não são consideradas e são repostos os valores dos pesos da ultima época válida. O número de épocas considerado para a falha de validações é baseado em valores típicos utilizados em redes neurais.

4.6.3 Gradiente Mínimo

Quando o gradiente tem um valor muito baixo significa que estamos muito perto do valor ótimo do erro quadrático médio, ou seja do mínimo da função de erro, e o ganho obtido em relação ao gradiente nulo é desprezável. O valor do gradiente mínimo considerado é de 1^{-7} sendo um valor típico.

4.6.4 Coeficiente de Aprendizagem Máximo

Quando o coeficiente de aprendizagem atinge um valor suficientemente elevado, a variação dos pesos é muito pequena e não existe nenhum ganho significativo. Este critério está bastante relacionado com o gradiente mínimo pois quando o valor do erro quadrático médio atinge valores muito perto do mínimo, o coeficiente de aprendizagem tende para infinito e o gradiente tende para zero. O valor considerado para o máximo do coeficiente de aprendizagem é de 1^{10} sendo um valor típico.

4.7 Número de Neurónios

Para uma rede neuronal se aproximar a uma função complexa como a da atenuação de sinal rádio é necessário treinar uma rede suficientemente grande para que consiga adaptar à função pretendida. Uma rede com um número de neurónios for demasiado elevado perde eficiência na fase de aprendizagem pois demora mais tempo para convergir.

Para determinar o número ótimo de neurónios necessários foi criada uma rede multicamada com quatro neurónios e treinou-se a rede para cada uma das linhas ferroviárias estudadas neste trabalho, para cada uma das linhas foi se aumentando o número de neurónios para verificar o erro quadrático médio em função do número de neurónios da rede.

Na figura 23 está representada a primeira rede treinada para cada uma das linhas, para determinar o número ótimo de neurónios treinou-se a rede várias vezes aumentando o número de neurónios e camadas sendo que foi considerado um máximo de quatro camadas.




Figura 23 - Rede Neuronal Multicamada.

Na figura 24 está representado o erro obtido em função do número de neurónios, observa-se que o erro é mínimo nos três casos entre 40 a 60 neurónios. Devido ao facto do treino de uma rede neuronal depender de variáveis geradas aleatoriamente é necessário considerar uma margem no número de neurónios a considerar para posteriormente se ajustar o número de neurónios das várias redes até se obter uma solução ótima.




Figura 24 - RMSE vs Número de neurónios.

4.8 Análise de Parâmetros

Em redes neuronais, os valores de entrada mais relevantes são ligados a mais neurónios de entrada. Para determinar a influência de cada parâmetro treinou-se uma rede neuronal com apenas a distância, sendo o parâmetro mais determinante no decaimento de qualquer sinal rádio, e posteriormente adicionou-se outro parâmetro e verificou-se o ganho que esse parâmetro adiciona na estimação de sinal. Este processo foi repetido para todos os parâmetros e para as três linhas ferroviárias, e os vários ganhos obtidos são comparados entre si.

A rede treinada, representada na figura 25, é composta por duas camadas, uma camada de entrada com dez neurónios e uma camada de saída com apenas um. O parâmetro da distância é ligado a todos os neurónios de entrada e os parâmetros adicionais são ligados a três.




Figura 25 - Rede neuronal para análise de parâmetros.

Com base nos vários ganhos obtidos de cada parâmetro pretende-se criar quatro classes de parâmetros para cada uma das linhas ferroviárias em que a classe 1 representa os parâmetros mais influentes e a classe 4 os menos influentes.

4.9 Redes Neurais Otimizadas para cada Linha

Na secção anterior dividiu-se os vários parâmetros em quatro classes para cada uma das linhas ferroviárias. Devido ao facto das linhas apresentarem ambientes de propagação diferentes é esperado que a classificação para cada uma delas seja diferente e por isso serão criadas três redes neuronais com classificações diferentes. A classificação de cada linha foi escolhida com base nos ganhos de cada parâmetro obtidos na experiência anterior, ou seja, os parâmetros com o maior ganho na estimação de sinal são considerados mais relevantes e são ligados a mais neurónios da camada de entrada.

Na figura 26 está representada a camada de entrada das três redes treinadas para cada uma das linhas, a distribuição das classes é feita conforme está representado na figura, em que aos parâmetros da classe um são ligados a todos, e ao longo dos neurónios são inseridas as restantes classes por ordem de importância.

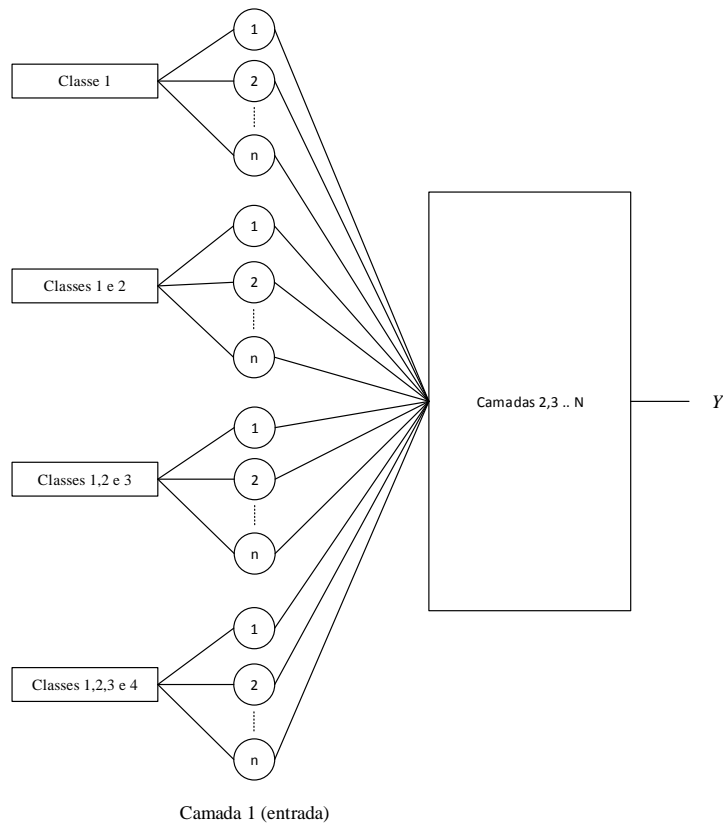


Figura 26 - Rede neuronal com classes.

4.10 Aproximação à função de Okumura-Hata

Durante o estudo das redes neurais notou-se que existem semelhanças entre a função de Okumura-Hata e a função de saída de um perceptrão, sendo composta por uma soma de multiplicações. Nesta fase pretende-se seguir uma abordagem diferente que consiste em, através de um perceptrão, determinar os parâmetros de calibração ótimos do modelo de Okumura-Hata para comparação com resultados obtidos por outros meios.

Nesta experiência considera-se como valores de entrada, os fatores do modelo. Para isto é necessário pré calcular os vários fatores antes de serem apresentadas ao perceptrão. Após o cálculo dos vários fatores é necessário normaliza-los para que estes variem entre o mesmo intervalo de valores.

Na figura 27 está representado um perceptrão com dezassete valores de entrada. A função de ativação considerada é a função linear em que o nível de atividade do perceptrão é passado diretamente para a saída. A função de saída do perceptrão é dada pela expressão descrita em (29).

$$Y = 1 * w_1 + x_2 w_2 + x_3 w_3 + x_4 w_4 + x_5 w_5 + x_6 w_6 x_7 w_7 + x_8 w_8 + x_9 w_9 + x_{10} w_{10} + x_{11} w_{11} + x_{12} w_{12} + x_{13} w_{13} + x_{14} w_{14} + x_{15} w_{15} + x_{16} w_{16} + x_{17} w_{17} \quad (29)$$

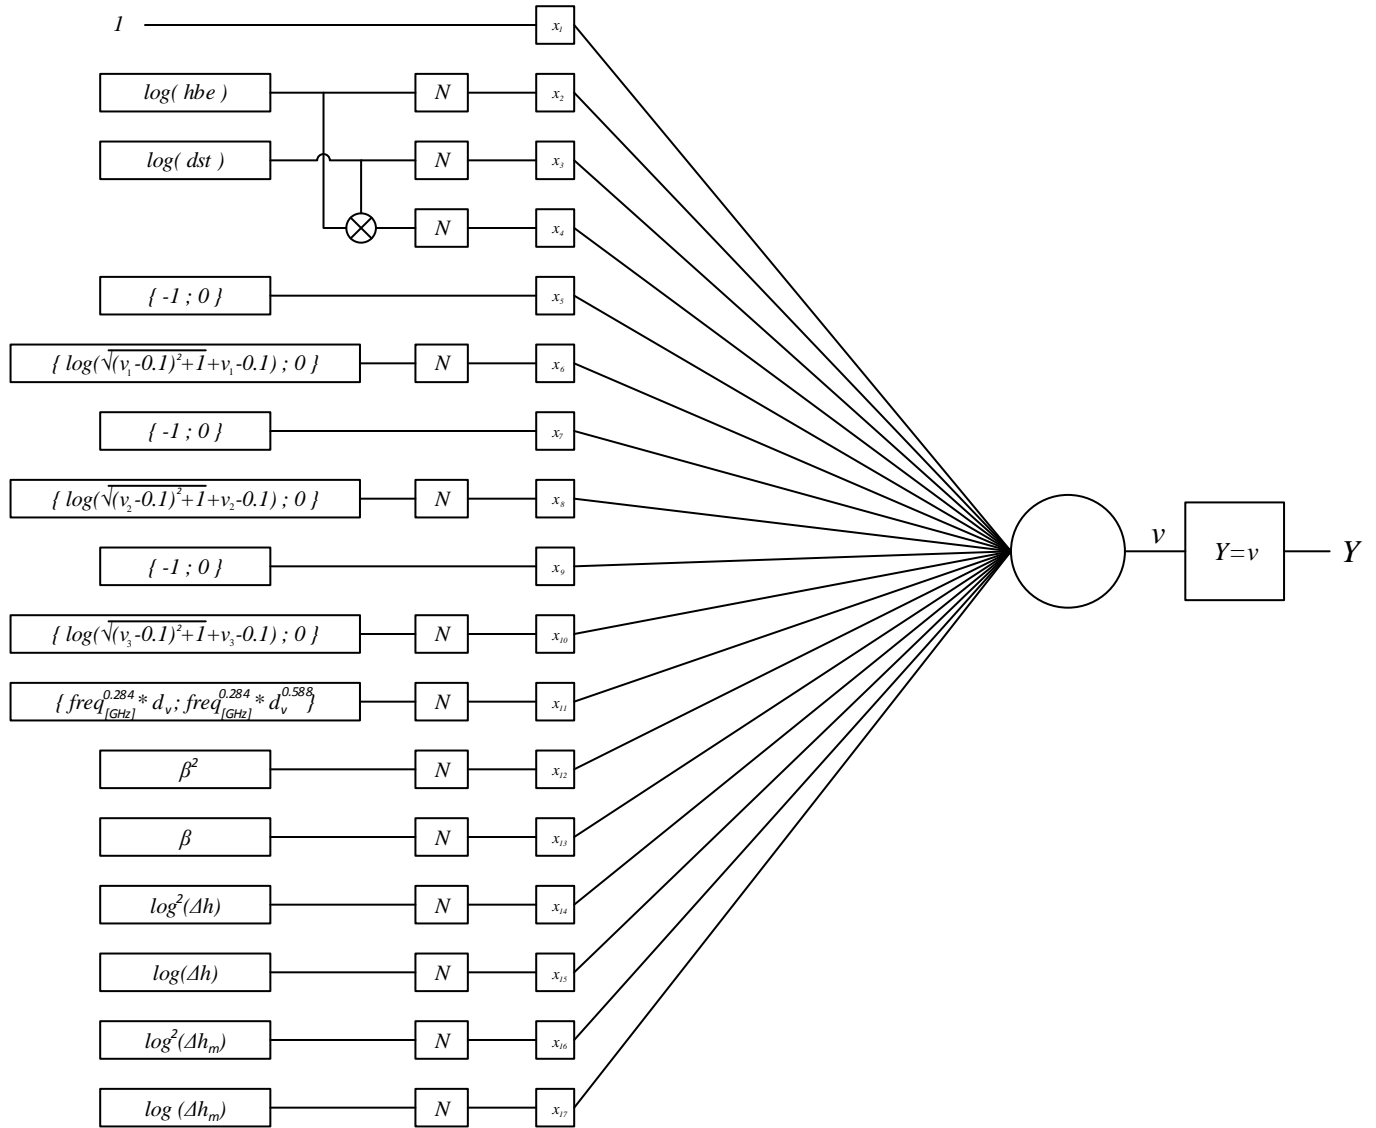


Figura 27 – Perceptrão.

A expressão representada em (29) descreve a função de saída do neurónio representado na figura 27. As variáveis x_1, x_2, \dots, x_{17} representam os valores de entrada do modelo pré calculados e normalizados, e os pesos w_1, w_2, \dots, w_{17} representam os parâmetros de calibração do modelo normalizados. A parte constante, representada em (30), da expressão é representada pelo peso w_1 , que se vai aproximar a esse valor à medida que a rede é treinada.

$$Lp(constante) = a1 + a2 * \log(f_{[MHz]}) - a(h_m) \quad (30)$$

O fator corretivo K_{acl} , representado em (31), é calculado em função da distância da estação base à estação móvel e por isso é considerado pela rede no peso w_3 .

$$K_{acl}(d)_{[dB]} = c_1 * \log(d_{[km]}) + c_2 \quad (31)$$

4.11 Classificação de Ambientes

Durante este trabalho verificou-se que uma rede neuronal apenas consegue estimar o comportamento da função de atenuação de sinal em ambientes semelhantes àqueles que foi treinado. Pretende-se criar uma rede neuronal capaz de determinar o tipo de ambiente de uma determinada amostra, com base na parametrização de terreno para reencaminhar essa amostra para uma rede neuronal treinada previamente para esse tipo de ambiente. Com esse objetivo treinou-se uma rede competitiva para dividir as várias amostras em diferentes tipos de ambiente utilizando como valores de entrada da rede os parâmetros que caracterizam o terreno entre a estação base e a estação móvel.

Parâmetros considerados	Tipo de terreno
V_1	Terreno com obstáculos
Δ_h	Terreno montanhoso
β	Terreno com presença de água
d_v	Terreno com vegetação

Tabela 13 - Classificação de ambiente.

Na tabela 13 estão representados os tipos de ambiente considerados na classificação de ambientes. O conjunto de amostras consideradas para a fase de treino é dividido igualmente em dois, em que metade é utilizado para a classificação, e as restantes utilizadas para o treino das várias redes treinadas posteriormente.

Para o treino a rede competitiva são considerados 40% do total de amostras sendo que estas amostras são divididos em cinco conjuntos, amostras com obstáculos, amostras com forte ondulação do terreno, amostras com presença de água, amostras com vegetação e amostras sem obstáculos, ondulação, água ou vegetação. Os conjuntos de amostras menores são replicados para que o número de amostras de cada conjunto seja o mesmo.

No dimensionamento da rede considerou-se um total de quatro neurónios na camada competitiva o que significa que a rede vai produzir no máximo quatro classes distintas caracterizadas pelos parâmetros descritos na tabela 13.

4.12 Redes Neurais com Classificação de Ambientes

Na secção anterior treinou-se uma rede neuronal utilizando a aprendizagem competitiva com o objetivo definir classes de amostras consoante o tipo de ambiente. A rede competitiva foi treinada com 40% do total das amostras.

Nesta fase classificou-se outras 40% de amostras com a rede competitiva e treinou-se quatro redes neurais para cada um dos tipos de ambientes. Para testar o desempenho da aplicação testou-se as redes usando as restantes 20% de amostras não utilizadas para treino de nenhuma das redes.

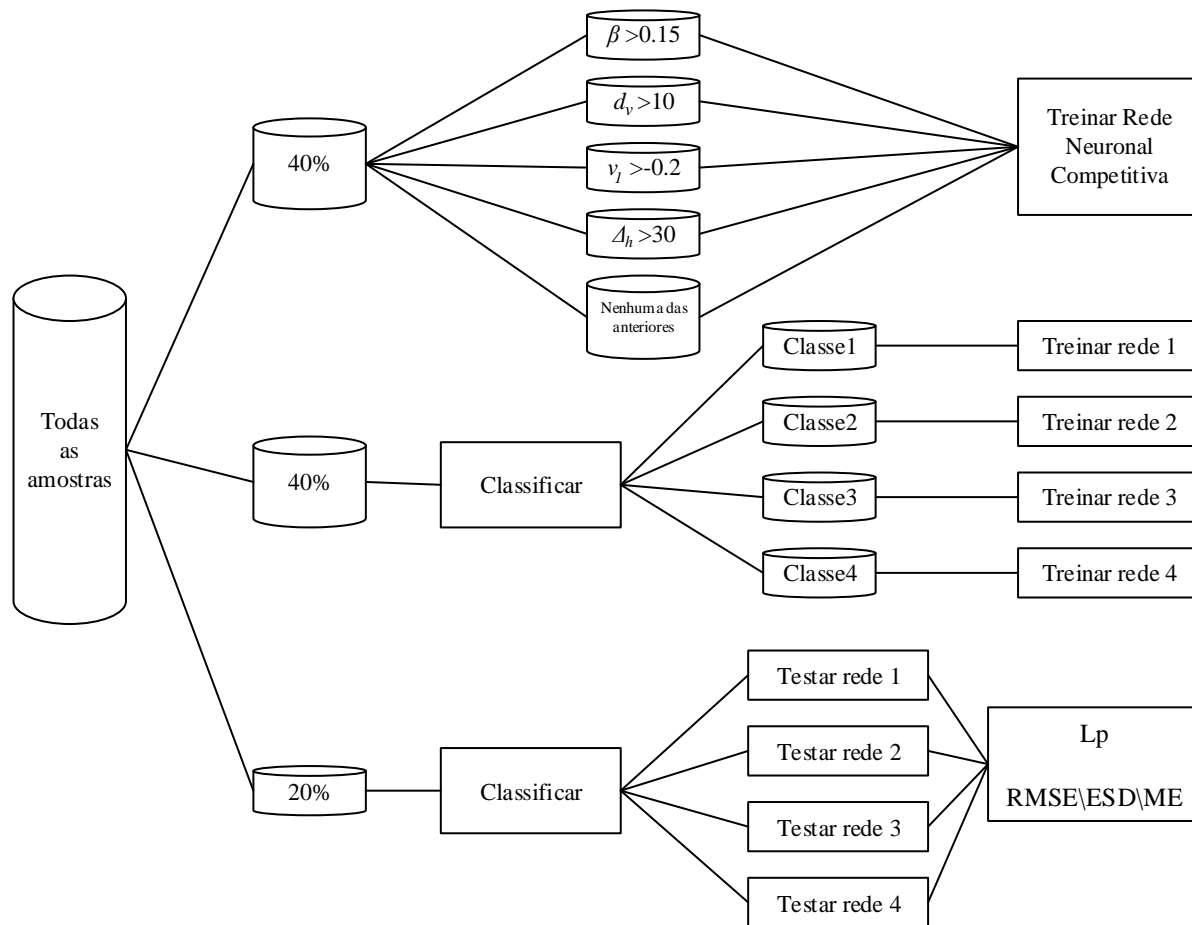


Figura 28 - Aplicação baseada em redes neurais.

Na figura 28 está representado o diagrama da fase de treino e da fase de teste das várias redes envolvidas. As amostras são divididas em 40% para treino da rede competitiva, 40% para treino das várias redes neurais, sendo que dessas 40%, 24% são para treino e 16% são para validação. As restantes 20% não utilizadas na fase de treino são usadas para testar o desempenho geral do sistema.

Posteriormente serão testadas as amostras de cada linha para verificar o erro de estimação em cada uma das linhas ferroviárias e os resultados serão comparados com os resultados obtidos em estudos anteriores. As várias redes serão dimensionadas com base na classificação feita previamente pela rede competitiva classificadora e no estudo feito nos capítulos anteriores.

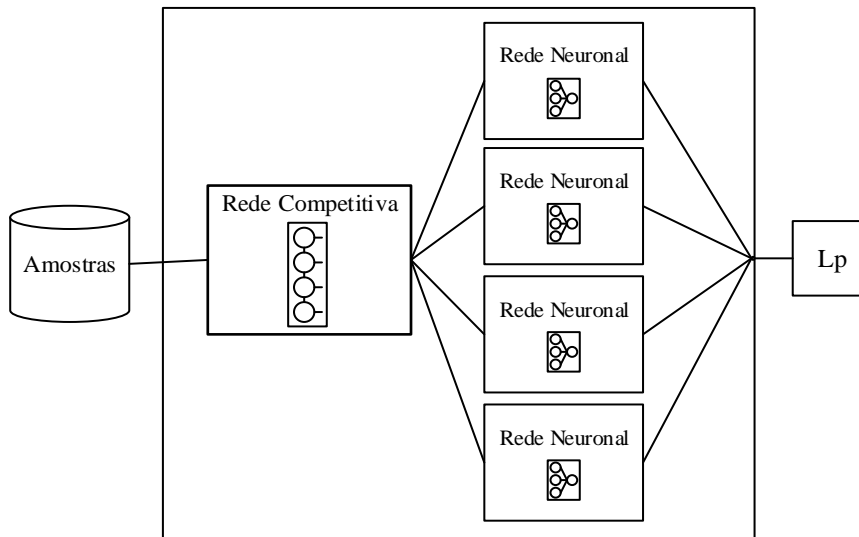


Figura 29 - Diagrama de blocos.

Na figura 29 está representado o diagrama de blocos da aplicação desenvolvida, estando as redes treinadas, uma amostra entra na rede competitiva, é classificada com base nos parâmetros que caracterizam o tipo de terreno entre a estação base e estação móvel, e entra na respectiva rede neuronal treinada previamente para o mesmo tipo de ambiente.

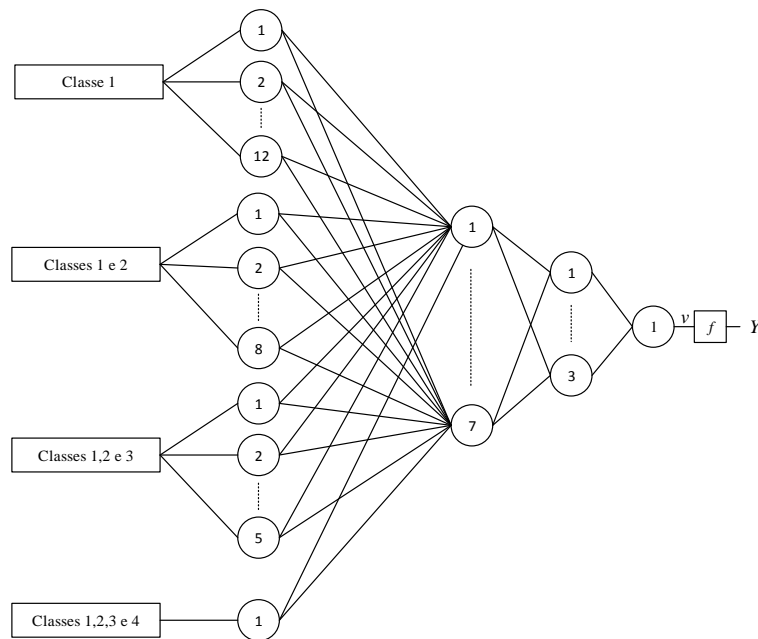


Figura 30 - Rede neuronal após classificação

Na figura 30 está representada a arquitetura das redes neuronais utilizadas após a rede competitiva. As classes dos valores de entrada foram obtidos, através da análise descrita na secção 4.8, para cada um dos quatro ambientes. Os 40% de amostras selecionadas para treino das redes neuronais são classificadas pela rede competitiva, dividindo as amostras em quatro conjuntos, em que cada conjunto é utilizado para treinar cada uma das redes.

Posteriormente, para testar o desempenho do sistema, são utilizadas as restantes 20% de amostras não utilizadas em nenhuma fase de aprendizagem, e calculado o erro de cada uma das redes assim como o erro geral do total das 20% de amostras. Por fim são apresentadas ao sistema as amostras das três linhas ferroviárias individualmente para verificar o desempenho do sistema para cada uma das linhas. Os resultados obtidos serão comparados com os resultados obtidos em [17].

Análise de Resultados

Durante esta dissertação foram implementadas várias redes neurais, seguindo diferentes abordagens, com o objetivo de encontrar alternativas, aos métodos tradicionais, à estimação de cobertura rádio em sistemas GSM-R. Esta dissertação propõe uma alternativa que se abstrai do modelo de propagação e utiliza algoritmos de aprendizagem supervisionada e não supervisionada baseados em perceptrões para chegar a uma função de atenuação para os vários casos de estudo assim como uma solução generalizada.

Este capítulo apresenta os resultados obtidos nas diferentes abordagens seguidas durante todo este trabalho. Compara-os entre si, e compara-os com os resultados obtidos através do modelo de Okumura-Hata.

5.1 Estatística do Erro

Para comparar o desempenho das várias redes é necessário definir uma métrica que se aplica aos vários métodos utilizados em estimação de cobertura rádio. O desempenho dos vários métodos é definido pela raiz do erro quadrático médio (RMSE), calculada através de (34), pelo desvio padrão estimado (ESD), calculado através de (35), e pelo erro médio (ME), calculado através de (33).

Neste trabalho, no cálculo de desempenho das várias redes, apenas são consideradas 20% das amostras, selecionadas aleatoriamente do conjunto total de amostras e não utilizadas durante a fase de treino, para garantir uma boa avaliação das redes treinadas.

$$ME = \frac{1}{N} \sum_{i=1}^N |P_{medido_i} - P_{estimado_i}| \quad (33)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |P_{medido_i} - P_{estimado_i}|^2} \quad (34)$$

$$ESD = \sqrt{\frac{1}{N} \sum_{i=1}^N (|P_{medido_i} - P_{estimado_i}| - ME)^2} \quad (35)$$

5.2 Análise de parâmetros

No dimensionamento de uma rede neuronal é necessário definir quais os parâmetros mais relevantes no cálculo do resultado à saída para que os parâmetros mais relevantes sejam ligados a mais neurónios da camada de entrada da rede. Com este objetivo treinou-se e testou-se a rede descrita na secção 4.8 para cada parâmetro e para cada linha. Na tabela 14 estão representados os ganhos por parâmetro de cada uma das linhas. Com base nestes resultados foram criadas quatro classes de parâmetros de entrada ordenados pela sua relevância em que os parâmetros com o maior ganho são considerados mais relevantes.

Parâmetro	Évora	Cascais	Algarve
Altura efetiva (h_{be})	1.28 dB	2.63 dB	1.46 dB
Obstáculo principal (v_1)	0.88 dB	1.95 dB	2.35 dB
Obstáculo de 2ª ordem (v_2)	0.65 dB	0.8 dB	0.7 dB
Obstáculo de 2ª ordem (v_3)	0.64 dB	0.8 dB	0.72 dB
Vegetação (d_v)	1.6 dB	0.15 dB	0.39 dB
Água (β)	0.15 dB	2.16 dB	0.55 dB
Ondulação (Δh)	1.01 dB	0.92 dB	1.67 dB
Posição na ondulação (Δh_m)	0.58 dB	2.59 dB	1.16 dB

Tabela 14 - Resultado da análise de parâmetros.

Na figura 31 está representado graficamente o ganho de cada parâmetro para cada um dos cenários considerados. Através dos resultados apresentados no gráfico é possível determinar os parâmetros mais relevantes em cada um dos cenários. Com base nesta informação, os vários parâmetros são divididos em quatro classes consoante a sua relevância.

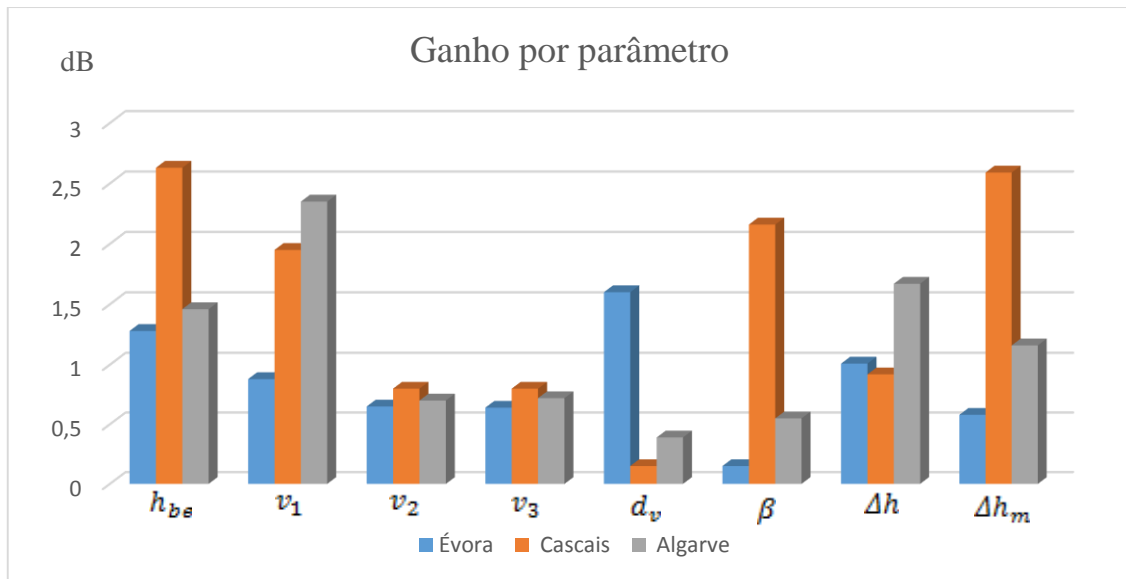


Figura 31 - Ganho por parâmetro.

Na tabela 15 estão definidas as várias classes de parâmetros de entrada, com base nesta classificação foram treinadas três redes neuronais, uma para cada linha, em que os parâmetros mais relevantes entram em mais neurónios de entrada.

Classe	Évora	Cascais	Algarve
1	d	d	d
2	$d_v, h_{be}, \Delta h$	$h_{be}, \Delta h_m, \beta, v_1$	$v_1, \Delta h, h_{be}, \Delta h_m$
3	$v_1, v_2, v_3, \Delta h_m$	$\Delta h, v_2, v_3,$	v_2, v_3, β
4	β	d_v	d_v

Tabela 15 - Definição das classes de parâmetros.

Pela tabela 15 nota-se que existem diferenças na relevância dos vários parâmetros nos três cenários considerados. A linha de Évora, por se tratar de uma zona rural, tem como parâmetros de maior relevância a caracterização da vegetação, da ondulação do terreno e a altura efetiva. A linha de Cascais, por se tratar de uma zona suburbana com a presença de superfícies aquáticas em quase toda a linha, tem como parâmetros de maior relevância a caracterização da presença de água e dos obstáculos presentes entre a estação base e os vários pontos medidos. Devido ao facto da linha apresentar zonas com maior altitude é também considerada a altura efetiva e a posição na ondulação do terreno. A linha do Algarve apresenta uma forte relevância da ondulação do terreno sendo considerados mais relevantes os parâmetros da ondulação do terreno e a altura efetiva. Por se tratar de uma zona suburbana com bastantes obstáculos, é também considerado como parâmetro de maior relevância a caracterização dos obstáculos presentes entre as estações base e os pontos medidos.

5.3 Redes Otimizadas para cada Cenário

Numa primeira fase pretendeu-se estudar cada cenário individualmente e com o objetivo de minimizar ao máximo o erro na estimação de sinal em cada uma das linhas ferroviárias. Na figura 32 está representada a rede treinada para ca um dos cenários.

Os resultados obtidos por uma rede neuronal não são determinísticos pois na sua inicialização os pesos são gerados aleatoriamente assim como o conjunto das amostras é selecionado aleatoriamente do conjunto total de amostras e por este motivo as redes foram treinadas várias vezes. Verificada a consistência das várias fases de treino optou-se por utilizar redes que, apesar de não convergirem para a mesma solução, convergem para uma solução em que erro varia o menos possível em cada treino.

Foram experimentadas várias arquiteturas de rede diferentes analisando a consistência e o erro obtido e a chegou-se à solução proposta na figura 32.

A rede consiste de 41 neurónios de entrada, em que, a classe 1 entra nos 41, a classe 2 entra em 16, a classe 3 em 6 e a classe 4 em apenas 1. A rede tem 2 camadas intermédias, tendo a primeira 7 neurónios e a segunda 3. A camada de saída consiste de apenas 1.

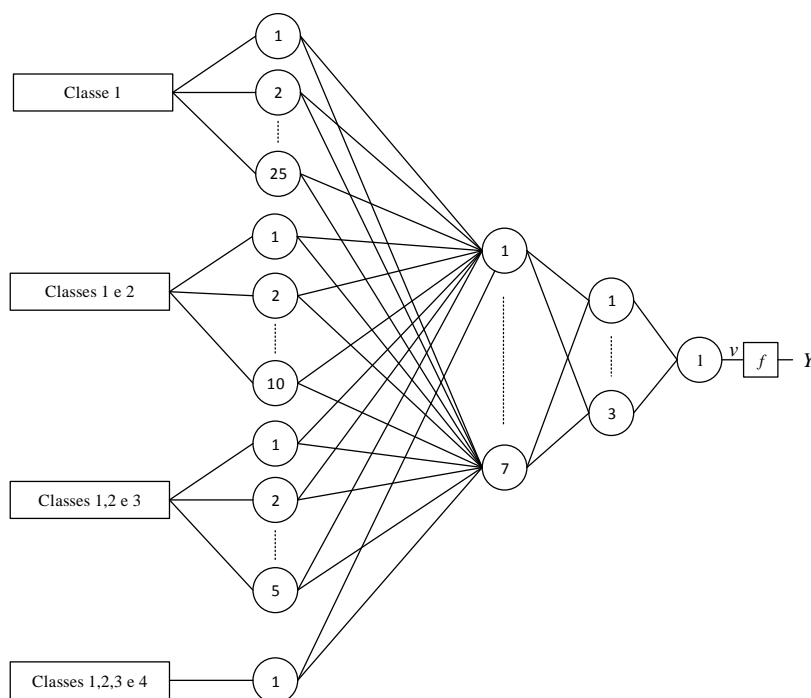


Figura 32 - Rede neuronal otimizada para cada cenário.

As seguintes secções descrevem os resultados produzidos pela rede representada na figura 32 em cada um dos cenários.

5.3.1 Linha de Évora

O primeiro cenário considerado para treinar a rede é a linha de Évora. Caracteriza-se por um ambiente rural com espaços abertos em que o sinal rádio se comporta de forma bastante monótona em relação aos restantes cenários. Na tabela 16 estão representadas as estatísticas da fase de aprendizagem neste cenário.

Número de Épocas	196
Tempo de treino	0:03:09
Erro quadrático médio (amostras de validação)	0.00113
Gradiente	0.00128
Coefficiente de aprendizagem	1.26e-06
Validações Falhadas	6

Tabela 16 - Estatísticas de treino na linha de Évora.

Pela tabela 17 nota-se que a fase de aprendizagem terminou pelo número máximo de validações falhadas, a rede atingiu um erro quadrático médio de 0.00113 o que significa que a rede convergiu corretamente.

	Rede Neuronal	Modelo de Okumura-Hata Otimizado
RMSE	3.1077 dB	6.04 dB
ESD	2.4917 dB	4.51 dB
ME	2.2823 dB	4.02 dB

Tabela 17 – Erro obtido na Linha de Cascais.

Pela tabela 17 nota-se que existe uma diminuição de aproximadamente 3 dB no RMSE obtido através da rede neuronal. Conclui-se que a rede em causa apresenta uma boa solução na estimação de sinal na linha de Évora.

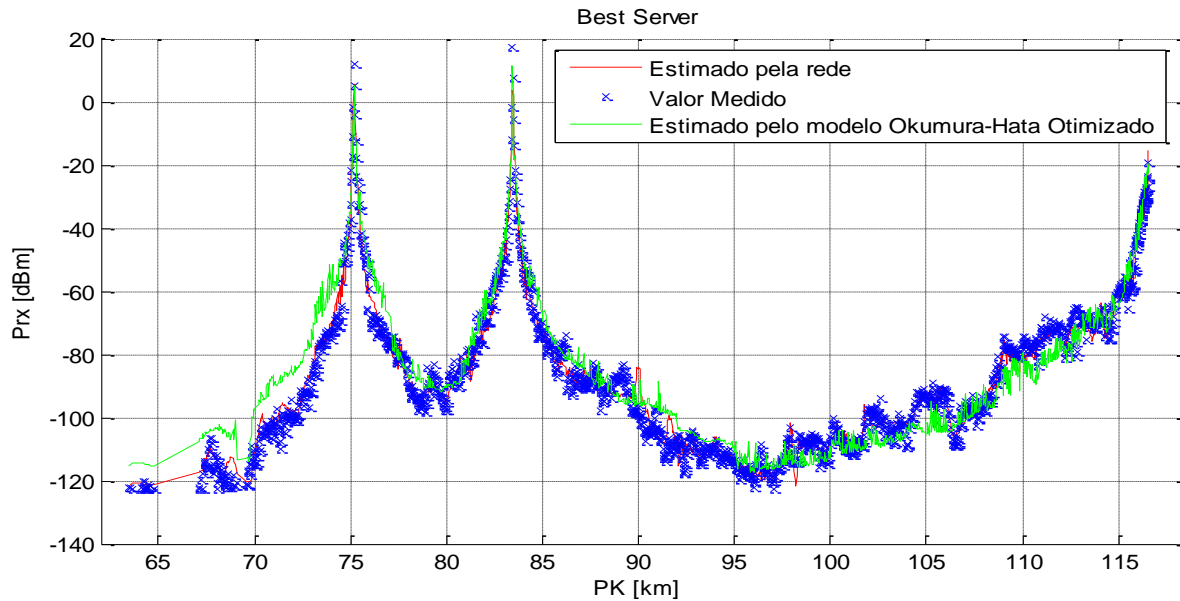


Figura 33 – Best Server, linha de Évora

Na figura 33 está representado a segunda viagem de testes da linha de Évora. Pela figura nota-se que existe uma melhoria na estimação de sinal, especialmente entre o ponto quilométrico 70 e 75. Apesar do modelo de Okumura-Hata Otimizado produzir uma estimação muito próxima do valor real, é possível visualmente notar que a rede neuronal produz uma estimação mais precisa.

5.3.2 Linha de Cascais

O segundo cenário considerado foi a linha de Cascais. A linha caracteriza-se pela presença de água ao longo de quase toda a linha e por um ambiente suburbano. Esta linha diferencia-se das restantes por já ter o sistema GSM-R instalado e operacional.

Número de Épocas	102
Tempo de treino	0:00:24
Erro quadrático médio (amostras de validação)	0.00269
Gradiente	0.000902
Coefficiente de aprendizagem	2.15e-4
Validações Falhadas	6

Tabela 18 - Estatísticas de treino na linha de Cascais.

Na tabela 18 estão indicadas as estatísticas resultantes da fase de aprendizagem da rede treinada para a linha de Cascais. Nota-se que o tempo de treino foi mais reduzido em comparação com a linha de Évora devido ao facto do sistema já se encontrar em funcionamento, e por isso existem um menor número de amostras pois apenas é feita uma viagem de teste.

	Rede Neuronal	Modelo de Okumura-Hata Otimizado
RMSE	5.6180 dB	10.61 dB
ESD	4.7685 dB	6.8 dB
ME	3.6443 dB	8.14 dB

Tabela 19 – Erro obtido na linha de Cascais.

Na tabela 19 está representado o erro obtido na estimação de sinal na linha de Cascais. Notou-se que apesar do erro ser mais elevado que na linha de Évora, existe um ganho bastante elevado em relação à estimação obtida pelo modelo de Okumura-Hata Otimizado.

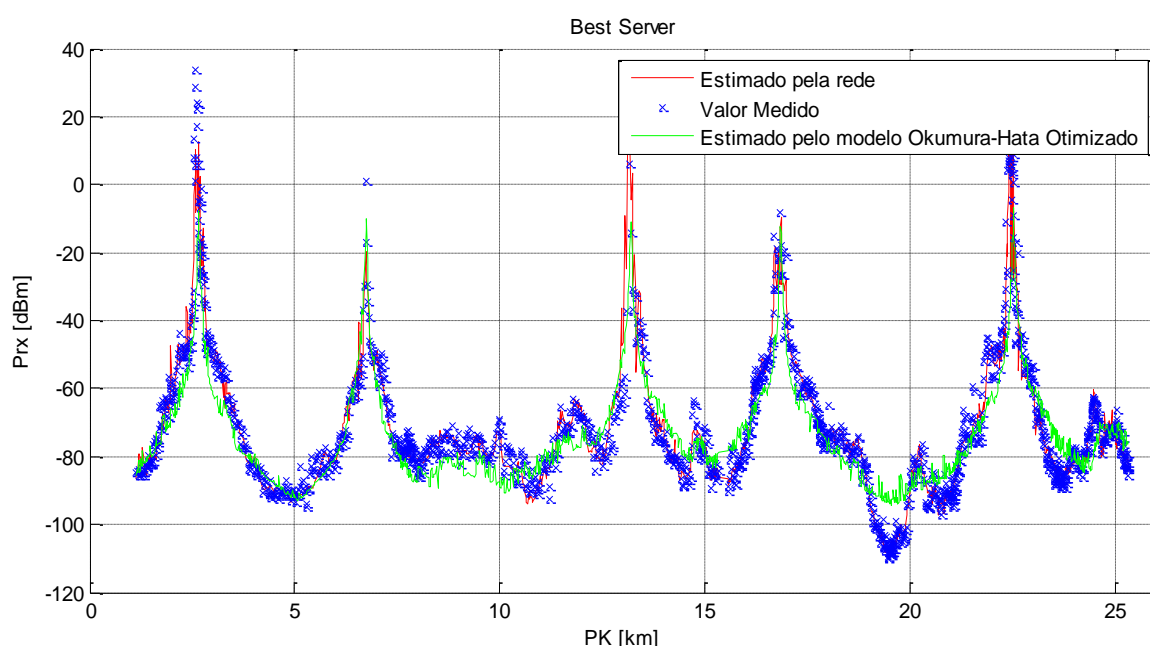


Figura 34 - Best Server, linha de Cascais.

Na figura 34 está representado o nível de sinal estimado e medido na linha de Cascais. Nesta linha o sistema de comunicações móveis GSM-R já se encontra em funcionamento e na figura está representado o nível de sinal das cinco estações base da linha. Apesar de existir um aumento do erro em relação à linha de Évora, visualmente, o valor estimado pela rede neuronal é bastante aproximado do valor real. Entre o ponto quilométrico 18 e 20 nota-se que existe uma discrepância no valor estimado por parte do modelo otimizado devido ao facto de, nessa zona, o sinal apresentar níveis bastante baixos.

5.3.3 Linha do Algarve

O terceiro cenário considerado foi a linha do Algarve. Esta linha caracteriza-se por um ambiente suburbano e pela presença de obstáculos entre as estações base e os vários pontos da linha. O sistema

GSM-R em Portugal ainda se encontra em fase de planeamento e implementação em muitas linhas ferroviárias do país e durante o estudo anterior ainda não tinha sido efetuada a campanha de medidas na linha do Algarve. Por esta razão não é possível a comparação de resultados obtidos neste trabalho com os resultados obtidos em estudos anteriores. Para efeitos de comparação é utilizado como referência a estimação obtida através do modelo de Okumura-Hata original.

Número de Épocas	172
Tempo de treino	0:02:42
Erro quadrático médio (amostras de validação)	0.00295
Gradiente	0.0265
Coefficiente de aprendizagem	1.70e-06
Validações Falhadas	6

Tabela 20- Estatísticas de treino na linha do Algarve.

Na tabela 20 estão representadas as estatísticas resultantes da fase de aprendizagem da rede neuronal otimizada para a linha do Algarve. Nota-se que o tempo de simulação aumentou em relação à linha de Cascais. Assim como as restantes redes, foi atingido o número máximo de validações falhadas.

	Rede Neuronal	Modelo de Okumura-Hata
RMSE	3.3017	12.3966 dB
ESD	2.6165	8.8561 dB
ME	2.4703	10.3029 dB

Tabela 21 - Erro obtido na linha do Algarve.

Na tabela 21 está representado o erro obtido na linha do Algarve. Como referido anteriormente, esta linha não foi caso de estudo no ano transato e apenas é comparado com os resultados obtidos através do modelo de Okumura-Hata original. Nota-se no entanto que existe uma grande diferença no erro obtido com uma diferença de quase 10 dB.




Figura 35 - Best Server, linha do Algarve

Na figura 35 está representada a quarta viagem de teste efetuada na linha do Algarve. Sendo apenas comparado com o modelo de Okumura-Hata original nota-se claramente a diferença do erro obtido, especialmente em pontos mais distantes das estações base. Os resultados obtidos nesta linha assemelham-se bastante aos resultados obtidos na linha de Évora.

5.3.4 Resumo de Resultados de Cada Linha

Durante esta fase foram treinadas redes otimizadas para cada um dos cenários para efeitos de comparação com resultados obtidos no ano transato utilizando algoritmos genéticos. Na tabela 22 estão resumidos os vários valores de erro obtidos nos três casos de estudo considerados neste trabalho.

Cenário	Erro	Modelo de Okumura-	Modelo de Okumura-	Rede
		Hata Original	Hata Otimizado	Neuronal
Évora	RMSE	14.9648 dB	6.04 dB	3.1077 dB
	ESD	10.7249 dB	4.51 dB	2.4917 dB
	ME	12.7208 dB	4.02 dB	2.2823 dB
Cascais	RMSE	10.964 dB	10.61 dB	5.6180 dB
	ESD	8.4754 dB	6.8 dB	4.7685 dB
	ME	8.7188 dB	8.14 dB	3.6443 dB
Algarve	RMSE	12.3966 dB	-	3.3017
	ESD	8.8561 dB	-	2.6165
	ME	10.3029 dB	-	2.4703

Tabela 22 - Resumo de resultados de redes otimizadas para cada cenário.

Pela tabela 22 nota-se que a linha de Cascais apresentou o maior valor de erro, tanto através de redes neuronais como através de algoritmos genéticos na obtenção de parâmetros otimizados do modelo de Okumura-Hata. No entanto o erro obtido pela rede neuronal é bastante reduzido e válido no âmbito da estimação de cobertura rádio. Na linha de Évora houve uma grande otimização por parte do modelo otimizado, com valores de erro bastante reduzidos, no entanto a rede neuronal conseguiu minimizar ainda mais o erro neste cenário apresentando uma solução ótima.

A linha do Algarve, apesar das características diferentes, apresentou valores de erro semelhantes às da linha Évora produzindo um ganho semelhante em relação ao modelo de Okumura-Hata original.

5.4 Alternativa Utilizando um Perceptrão

Nas secções anteriores foram treinadas três redes neuronais com o objetivo de obter uma solução que minimize o erro na estimação de cobertura em cada um dos cenários. Esta secção pretende testar uma alternativa à abordagem anterior para comparar com a solução apresentada na secção anterior.

A rede treinada é constituída por apenas um perceptrão e utiliza uma função de ativação puramente linear, como descrito na secção 4.10. Nesta abordagem pretendeu-se seguir a função de Okumura-Hata para que a rede se aproxime a esta função otimizando os vários parâmetros de calibração. Os parâmetros do modelo e fatores corretivos são pré calculados antes de entrarem no perceptrão.

Cenário	Erro	Modelo de Okumura-Hata Original	Modelo de Okumura-Hata Otimizado	Rede Neuronal	Perceptrão
Évora	RMSE	14.9648 dB	6.04 dB	3.1077 dB	6.9153 dB
	ESD	10.7249 dB	4.51 dB	2.4917 dB	5.1972 dB
	ME	12.7208 dB	4.02 dB	2.2823 dB	5.5999 dB
Cascais	RMSE	10.964 dB	10.61 dB	5.6180 dB	7.4910 dB
	ESD	8.4754 dB	6.8 dB	4.7685 dB	5.8695 dB
	ME	8.7188 dB	8.14 dB	3.6443 dB	5.6144 dB
Algarve	RMSE	12.3966 dB	-	3.3017 dB	6.5622 dB
	ESD	8.8561 dB	-	2.6165 dB	5.0898 dB
	ME	10.3029 dB	-	2.4703 dB	5.0848 dB

Tabela 23 - Resultados das diferentes abordagens.

Na tabela 23 estão representados os resultados obtidos das diferentes abordagens. Pela tabela nota-se que o perceptrão obteve um erro maior na linha de Évora em relação ao modelo de Okumura-Hata otimizado. A linha de Cascais continua a apresentar uma melhoria significativa em relação ao modelo

otimizado. O erro obtido nos vários cenários aumentou em relação à abordagem anterior e esta abordagem é apenas comparativa e não é considerada por esta dissertação como solução ao problema.

5.5 Classificação de Ambientes

Nas secções anteriores foram estudados os três cenários considerados neste trabalho individualmente com o objetivo de chegar a uma solução otimizada, que minimize o erro ao máximo, para cada cenário. Numa fase final pretendeu-se implementar uma aplicação baseada em redes neuronais capaz de estimar o nível de sinal recebido em qualquer um dos cenários obtendo um erro aceitavelmente baixo.

A solução proposta neste trabalho baseia-se em dividir as várias amostras em tipos de ambientes diferentes para serem apresentadas a uma rede neuronal otimizada para esse tipo de ambiente. Nesse âmbito foi treinada uma rede competitiva, como descrito na secção 4.12, de forma a classificar 40% do total de amostras e definir quatro ambientes distintos.

Número de Épocas	200
Tempo de Treino	03:41:25
Número de Neurónios	4
Percentagem de Amostras	40%

Tabela 24- Estatísticas da fase de treino de rede competitiva.

Na tabela 24 estão representadas as estatísticas da fase de aprendizagem da rede competitiva. Nota-se que o tempo de treino foi substancialmente mais elevado em relação às redes anteriores devido ao facto de, por se tratar de uma aprendizagem não supervisionada, não é aplicável o algoritmo de retro propagação de Levenberg-Marquardt, altamente otimizado para aprendizagem supervisionada.

Ambiente 1	Terreno com pouca vegetação
Ambiente 2	Terreno com obstáculos; Água até 51% ; Vegetação média (50m-180m)
Ambiente 3	Terreno com obstáculos altos; Terreno Ondulado; Sem água; Elevada Vegetação (>470m)
Ambiente 4	Terreno com obstáculos altos; Água até 12% ; Vegetação média (180m-460m)

Tabela 25 - Descrição dos ambientes definidos.

Na tabela 25 estão indicados os quatro ambientes definidos pela classificação da rede competitiva. Para cada um destes ambientes pretende-se otimizar e treinar uma rede neuronal que mais se adequa a às características de cada um dos ambientes.

5.6 Classificação de Parâmetros

Na tabela 26 estão representados os resultados da análise a cada parâmetro em cada um dos ambientes. Com base nos ganhos obtidos na tabela serão divididos em quatro classes de parâmetros para definir as ligações aos neurónios de entrada das várias redes. Os parâmetros cujo ganho é nulo ou negativo não são considerado na respetiva rede neuronal.

Parâmetro	Ambiente 1	Ambiente 2	Ambiente 3	Ambiente 4
Altura efetiva (h_{be})	1.09 dB	0.94 dB	0.11 dB	0.02 dB
Obstáculo principal (v_1)	1.97 dB	0.14 dB	- 0.1 dB	- 0.17 dB
Obstáculo de 2ª ordem (v_2)	0.75 dB	0.28 dB	0.12 dB	- 0.07 dB
Obstáculo de 2ª ordem (v_3)	0.76 dB	0.19 dB	- 0.03 dB	- 0.13 dB
Vegetação (d_v)	0.2 dB	0.25 dB	0.94 dB	0 dB
Água (β)	0.29 dB	0.5 dB	0.18 dB	0.24 dB
Ondulação (Δh)	0.86 dB	0.69 dB	1.15 dB	0.68 dB
Posição na ondulação (Δh_m)	1.2 dB	0.13 dB	0.15 dB	0.55 dB

Tabela 26 - Resultado de análise de parâmetros em diferentes ambientes.

Na tabela 27 estão representadas as quatro classes definidas para cada uma das redes e seus respetivos ambientes. Os ambientes 3 e 4 apenas têm apenas três classes de parâmetros pois não foram considerados os parâmetros com ganho nulo ou negativo.

Classe de parâmetro	Ambiente 1	Ambiente 2	Ambiente 3	Ambiente 4
1	d	d	d	d
2	$h_{be}, v_1, \beta, \Delta h_m$	$h_{be},$	Δh	$h_{be}, d_v, \Delta h, \Delta h_m$
3	v_2, v_3	$\Delta h, \beta$	-	-
4	d_v	$v_1, v_2, v_3, d_v, \Delta h_m$	$h_{be}, v_2, d_v, \beta,$ $\Delta h, \Delta h_m$	β

Tabela 27 - Definição de Classes de parâmetros para cada Ambiente.

5.7 Análise de Desempenho da Aplicação

Com base na classificação de parâmetros descrita na secção anterior foram treinadas quatro redes neuronais, uma para cada ambiente. Foram consideradas 40% de amostras, não utilizadas para treino da rede competitiva, para o treino das quatro redes. As amostras são classificadas previamente pela

rede competitiva e são treinadas as quatro redes. Para testar o desempenho das redes e do sistema são consideradas 20% de amostras, não utilizadas em nenhuma das várias fases de treino.

Ambiente	Número de amostras
1	3774
2	788
3	70
4	442

Tabela 28 - Número de amostras por ambiente

Na tabela 28 está representado o número de amostras obtidas após a classificação, por parte da rede competitiva, das 20% de amostras de teste consideradas para testar o desempenho do sistema. As amostras são majoritariamente classificadas em ambiente 1, e minoritariamente classificadas em ambiente 3.

Ambiente	Erro	Redes Neurais
Geral	RMSE	5.4043 dB
	ESD	4.4735 dB
	ME	3.8496 dB
Ambiente 1	RMSE	5.8101dB
	ESD	4.7037 dB
	ME	4.1938 dB
Ambiente 2	RMSE	4.3679 dB
	ESD	3.4992 dB
	ME	3.2144 dB
Ambiente 3	RMSE	3.1099 dB
	ESD	2.3695 dB
	ME	2.4515 dB
Ambiente 4	RMSE	3.3919 dB
	ESD	2.8399 dB
	ME	2.2641 dB

Tabela 29 - Erro obtido nos vários ambientes.

Na tabela 29 está representado o erro obtido testando as redes com as 20% de amostras de teste. Nota-se que o erro geral obtido sobre as amostras de teste é bastante reduzido produzindo uma solução valida para a generalização da estimação de cobertura rádio dos três casos de estudo.

5.8 Resultados Gerais

Nesta fase pretendeu-se criar uma aplicação baseada em redes neuronais que estimasse o nível de sinal recebido em qualquer um dos cenários considerados. Foi implementada uma aplicação com uma rede competitiva que classifica as várias amostras em diferentes ambientes para apresentar as várias amostras à rede que melhor se adequa às características da amostra em questão. Para uma avaliação final do desempenho do sistema é testado o sistema para cada uma das linhas para comparar os resultados obtidos com os resultados obtidos através dos modelos de propagação otimizados para esses mesmos cenários.

Cenário	Ambiente 1	Ambiente 2	Ambiente 3	Ambiente 4
Évora	4949	1566	328	1090
Cascais	2967	160	0	29
Algarve	10876	2296	15	1098

Tabela 30 - Número de amostras por ambiente

Na tabela 30 está representado o número de amostras de cada ambiente por cenário, nota-se que as amostras são maioritariamente classificadas em ambiente 1.

Linha	Erro	Redes Neuronais	Okumura-Hata otimizado
Évora	RMSE	4.7048 dB	6.04 dB
	ESD	3.8556 dB	4.51 dB
	ME	3.4119 dB	4.02 dB
Cascais	RMSE	7.3676 dB	10.61 dB
	ESD	6.3099 dB	6.8 dB
	ME	4.7752 dB	8.14 dB
Algarve	RMSE	4.8063 dB	-
	ESD	3.8971 dB	-
	ME	3.5707 dB	-

Tabela 31 – Comparação de resultados finais

Na tabela 31 está representado o erro obtido pelo sistema em cada um dos cenários. Nota-se que existe um pequeno aumento do erro em relação às redes otimizadas para cada um dos cenários.

Apesar do aumento do erro, o desempenho do sistema foi superior ao modelo de Okumura-Hata otimizado e prova-se que a solução proposta por esta dissertação apresenta bons resultados minimizando o erro na estimação de cobertura rádio, em sistemas GSM-R, tanto em casos gerais como em casos específicos.

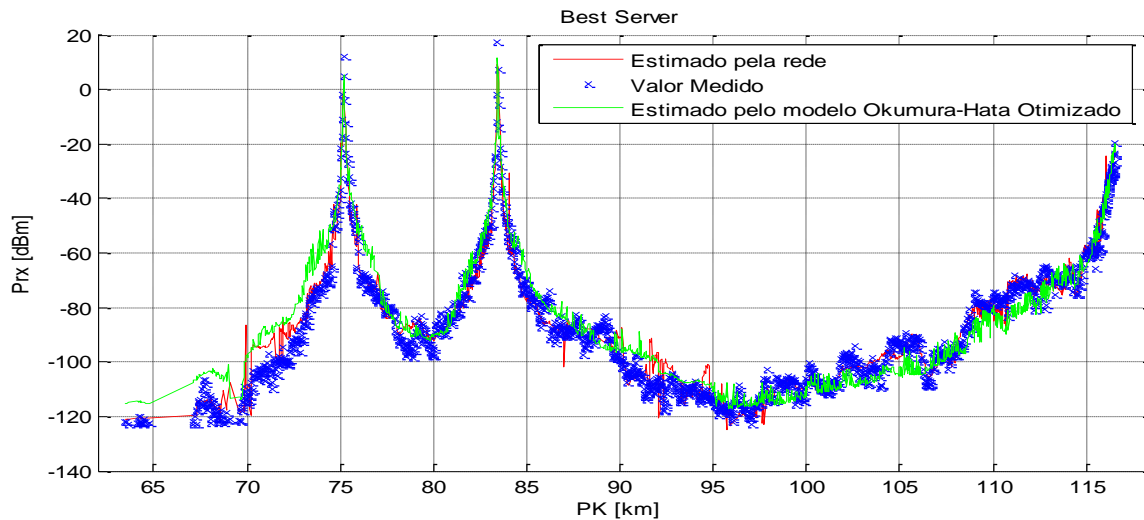


Figura 36 - Best Server, linha de Évora.

Na figura 36 está representada a segunda viagem de teste na linha de Évora. O nível de sinal estimado pela aplicação aproximasse bastante do valor medido apresentando uma solução válida na linha de Évora. Visualmente nota-se que a curva está ligeiramente mais próxima dos pontos medidos em relação à estimação obtida através do modelo de Okumura-Hata otimizado para a linha de Évora.




Figura 37 - Best Server, linha de Cascais.

Na figura 37 está representado o nível de sinal estimado e medido ao longo da linha de Cascais. Este cenário foi o que apresentou o maior erro na estimação de sinal e é possível verificar visualmente que em algumas partes da linha existe um ligeiro desvio em relação aos pontos medidos. No entanto a

rede apresenta um erro menor em relação ao modelo de Okumura-Hata otimizado para esse cenário e considera-se uma solução válida no contexto desta linha.

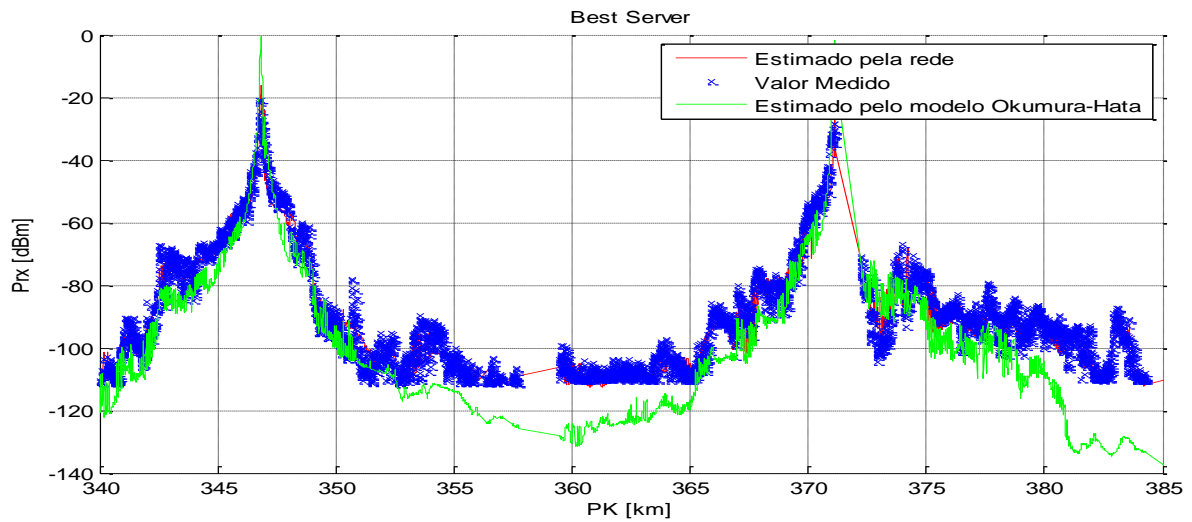


Figura 38 - Best Server, linha do Algarve.

Na figura 38 está representada a quarta viagem de teste da linha do Algarve. Por esta linha não ter sido alvo de estudo no ano transato apenas se apresenta como comparação, a estimação de sinal obtida pelo modelo de Okumura-Hata original. Visualmente nota-se que existe uma diferença significativa entre o modelo e a rede neuronal.

Capítulo 6

Conclusões

6.1 Trabalho Desenvolvido

Este trabalho teve como objetivo o desenvolvimento de algoritmos, baseados em redes neuronais, para efetuar a estimação de cobertura rádio em ambientes ferroviários. Pretende-se desta forma verificar a aplicabilidade das redes neuronais no contexto da estimação de cobertura rádio em redes GSM-R. Ao longo do trabalho foram criadas várias redes neuronais, começando com apenas um perceptrão, utilizando os parâmetros e fatores corretivos do modelo de propagação de Okumura-Hata como valores de entrada, e posteriormente aumentou-se o número de neurónios de forma a criar uma rede multicamada altamente adaptativa utilizando como valores de entrada apenas os parâmetros de terreno.

Após testar a rede multicamada verificou-se que as redes treinadas estavam muito específicas para os ambientes em questão, isto criou a necessidade de determinar o tipo de ambiente antes de proceder à estimação de cobertura. Com base na parametrização de terreno, treinou-se uma rede competitiva com o objetivo de classificar as amostras disponíveis em diferentes ambientes antes de serem apresentadas à rede. Assim, classificou-se as amostras disponíveis em diferentes tipos de ambiente e treinou-se uma rede neuronal para cada um dos ambientes.

6.2 Resultados Obtidos

Na primeira experiência realizada criou-se uma rede neuronal multicamada otimizada para cada linha ferroviária com o objetivo de minimizar o erro ao máximo em cada um dos cenários estudados. Verificou-se uma forte diminuição do erro nas linhas de Évora e Cascais em relação ao modelo de Okumura-Hata otimizado, a linha do Algarve, apenas comparada com o modelo de Okumura-Hata original apresentou uma forte diminuição do erro.

Após a primeira experiência treinou-se um perceptrão com os parâmetros e fatores corretivos do modelo de Okumura-Hata com o objetivo de se aproximar à função do modelo. Verificou-se um ligeiro aumento do erro em relação à experiência anterior sendo que na linha de Évora, o perceptrão apresentou um erro superior ao modelo de Okumura-Hata otimizado. Apesar do erro na linha de Évora se apresentar superior ao do modelo de Okumura-Hata otimizado, o perceptrão apresentou uma solução válida nos três cenários estudados.

Durante as experiências anteriores verificou-se que as redes otimizadas para cada cenário adaptaram-se demasiado aos ambientes que foram treinadas, ou seja, não foi possível treinar a rede para generalizar os três cenários. Para resolver este problema treinou-se uma rede competitiva para classificar as várias amostras em ambientes diferentes. Verificou-se que com esta abordagem foi possível treinar várias redes específicas para os vários ambientes e assim obter o menor erro possível quando se considerava amostras de todas as linhas para teste.

Em conclusão, esta dissertação verificou que, tanto para os casos gerais como para os casos específicos, a estimação de cobertura rádio em GSM-R através de redes neuronais apresenta uma alternativa viável a considerar em relação ao modelo de propagação teórico de Okumura-Hata original assim como o modelo de Okumura-Hata otimizado através de algoritmos genéticos. Com um ganho significativo em relação aos outros métodos de estimação de cobertura rádio é possível efetuar o planeamento de redes GSM-R com uma maior precisão diminuindo a margem de erro e assim reduzindo o número de estações base necessárias e o custo de instalação do sistema.

6.3 Trabalho Futuro

Para trabalho futuro propõe-se o desenvolvimento da solução final apresentada com uma rede competitiva que classifique as amostras previamente e as várias redes para cada classe. Neste trabalho apenas foram consideradas amostras de três linhas ferroviárias, propõe-se que se considere mais amostras de diferentes linhas ferroviárias com o objetivo de se criar mais tipos de ambientes e verificar o comportamento da rede criada.

Referências

- [1] - ANACOM - Autoridade Nacional de Comunicações, “O Sistema GSM-R” [Online]. www.anacom.pt, Acedido em: Agosto de 2014.
- [2] - Nuno Cota, António Serrador, Pedro Vieira, José Pestana Neves, António Rodrigues, "An Enhanced Radio Network Planning Methodology for GSM-R Communications," in Conftele 2013 - 9th edition of the Conference on Telecommunications, Castelo Branco, Portugal, 2013.
- [4] - Okumura, Y.; Ohmori, E.; Kawano, T.; Fukuda, K. “Field Strength and its Variability in VHF and UHF Land-Mobile Radio Service”. Review of the Electrical Communication Laboratory, Vol. 16, N° 9-10, October 1968.
- [5] - Hata, Masaharu, “Empirical Formula for Propagation Loss in Land Mobile Radio Services”. IEEE Transactions on Vehicular Technology, Vol. VT-29, N° 3, August 1980.
- [6] – Ana Beire, Nuno Cota, Helder Pita and António J. Rodrigues, “Automatic Tuning of Okumura-Hata Model on Railway Communications”, 17th International Symposium on Wireless Multimedia Communications (WPMC’14), Sydney, Australia, on September 2014
- [7] - Simon Haykin, “Neural Networks – A comprehensive Foundation”, Second Edition.
- [8] - Nuno Cota, António Serrador, Pedro Vieira, Ana Beire, António Rodrigues, "On the Use of Okumura-Hata Propagation Model on Railway Communications," in Wireless Personal Multimedia Communications Symposium (WPMC2013), Atlantic City, New Jersey, USA, 2013.

- [9] - ITU-R Recommendation P.1546, "Method for point-to-area predictions for terrestrial services in the frequency range 30 MHz to 3000 MHz," October 2001.
- [10] - J. Deygout, "Correction factor for multiple knife-edge diffraction," *Antennas and Propagation, IEEE Transactions on*, vol. 39, no. 8, pp. 1256-1258, August 1991.
- [11] - Mark A. Weissberger, "An initial critical summary of models for predicting the attenuation of radio waves by trees", 1982
- [12] - REFER Telecom / ISEL, "RailWave: User Manual", version 1.0, Janeiro 2013
- [13] - William C. Y. Lee , "Estimate of Local Average Power of a Mobile Radio Signal," *IEEE Trans. on Vehicular Technology*, vol. VT-34, no. 1, pp. 22-27, February 1985.
- [14] - Kenneth Levenberg, "A Method for the Solution of Certain Non-Linear Problems in Least Squares", 1944.
- [15] - Donald Marquardt, "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". *SIAM Journal on Applied Mathematics*, 1963.
- [16] - Haelterman, Rob, "Analytical study of the least squares quasi-Newton method for interaction problems". PhD Thesis, Ghent University, 2009
- [17] - Ana Gomes Beire, "Otimização de modelo de propagação utilizando Algoritmos genéticos: Caso das Comunicações Móveis em Ferrovia", Dezembro,2013