UNIVERSIDADE FEDERAL FLUMINENSE

ESCOLA DE ENGENHARIA

MESTRADO EM ENGENHARIA ELÉTRICA E DE TELECOMUNICAÇÕES

MELHORIA NA PREDIÇÃO DE COBERTURA DE SINAL RÁDIO MÓVEL *OUTDOOR-INDOOR* NA FAIXA DE 700 MHz ATRAVÉS DE REDES NEURAIS

MATHEUS BERNARDES DE MOURA

Niterói 2017

MATHEUS BERNARDES DE MOURA

MELHORIA NA PREDIÇÃO DE COBERTURA DE SINAL RÁDIO MÓVEL *OUTDOOR-INDOOR* NA FAIXA DE 700 MHz ATRAVÉS DE REDES NEURAIS

Dissertação apresentada ao curso de Mestrado em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de Concentração: Sistemas de Telecomunicações.

Orientadora: Prof^a Dra. Leni Joaquim de Matos

Coorientador: Prof. Dr. Tadeu Nagashima Ferreira

Niterói

2017

Ficha Catalográfica elaborada pela Biblioteca da Escola de Engenharia e Instituto de Computação da UFF

 M929 Moura, Matheus Bernardes de Melhoria na predição de cobertura de sinal rádio móvel *outdoorindoor* na faixa de 700 MHz através de redes neurais / Matheus Bernardes de Moura. – Niterói, RJ : [s.n.], 2017. 101 f.

Dissertação (Mestrado em Engenharia Elétrica e de Telecomunicações) - Universidade Federal Fluminense, 2017.

Orientadores: Leni Joaquim de Matos, Tadeu Nagashima Ferreira .

1. Sistema de telecomunicação. 2. Canal radiomóvel. 3. Rede neural artificial. I. Título.

CDD 621.382

MATHEUS BERNARDES DE MOURA

MELHORIA DA PREDIÇÃO DE COBERTURA DE SINAL RÁDIO MÓVEL OUTDOOR-INDOOR NA FAIXA DE 700 MHz ATRAVÉS DE REDES NEURAIS

Dissertação apresentada ao curso de Mestrado em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de Concentração: Sistemas de Telecomunicações

Aprovado em 12 de junho de 2017

Banca Examinadora

Dra. Leni Joaquim de Matos - Orientadora - UFF

Tuder Nagashima Ferrein

Dr. Tadeu Nagashima Ferreira - Coorientador - UFF

Perm 1 & costellar

Dr. Pedro Vladimir Gonzalez Castellanos - UFF

Dr. Edson/Luiz Gataldo Ferreira - UFF

melle

Dr. Gláucio Lima Siqueira - PUC-Rio

Niterói 2017

À minha esposa Debora, aos meus pais Humberto e Maria Emilia e irmã Raíssa, por sempre me incentivarem a nunca desistir.

Agradecimentos

A Deus, onipresente e soberanamente justo e bom dentre tantas outras características, e por me mostrar sempre o caminho certo.

À minha orientadora e Prof^a Dra Leni Joaquim de Matos e ao meu coorientador Prof. Dr. Tadeu Nagashima Ferreira, pelos ensinamentos, paciência e dedicação, motivos que me auxiliaram para que eu lograsse êxito.

À minha esposa Debora Lemos pelo constante incentivo e suporte, sempre ao meu lado qualquer que seja o caminho percorrido. Aos meus pais pelos valores passados.

Aos Professores do curso de Mestrado, que me proporcionaram o conhecimento necessário à implementação deste trabalho.

Aos gestores e colegas da área profissional pelo incentivo ao Mestrado.

Aos funcionários da Universidade Federal Fluminense pelo atendimento em permitir que as medições ocorressem na Universidade.

Aos alunos estagiários do Laboratório de Antenas e Propagação, Carla Florentino, Gabriel Alonso, Roberta Carvalho, Liliane Pacheco, Thainá Fernandes, e ao Mestre Fábio José, pelo auxílio nas medições para a realização desta dissertação.

SUMÁRIO

Agradeo	ciment	tos	6		
LISTA	DE FI	GURAS	9		
LISTA	LISTA DE TABELAS				
GLOSS	ÁRIO)	.11		
Resumo)		.12		
Abstrac	t		.13		
1.1	MO	TIVAÇÃO	14		
1.2	OB.	JETIVO	15		
1.3	DE	SCRIÇÃO DOS CAPÍTULOS	16		
2.1	ME	CANISMOS DE PROPAGAÇÃO	19		
2.1	.1	VISADA DIRETA	19		
2.1	.2	REFLEXÃO	20		
2.1	.3	DIFRAÇÃO	21		
2.1	.4	ESPALHAMENTO	22		
2.1	.5	REFRAÇÃO	23		
2.1	.6	ABSORÇÃO	24		
2.2	EFE	EITOS DA PROPAGAÇÃO	25		
2.2	.1	CARACTERIZAÇÃO EM FAIXA ESTREITA	25		
2.2	2	PERDA DE PERCURSO	26		
2.2	.4	DESVANECIMENTO EM GRANDE ESCALA	27		
2.2	.5	DESVANECIMENTO EM PEQUENA ESCALA	28		
3.1	MO	DELOS DE PROPAGAÇÃO EM MICROCÉLULAS	37		
3.1	.1	COST 231-WALFISCH-IKEGAMI MODEL	37		
3.2	MO	DELOS DE PROPAGAÇÃO INDOOR	40		
3.2	.1	MODELO MULTI-WALL	40		
3.2	2	MODELO DE ATENUAÇÃO LINEAR	41		
3.3	MO	DELO DE PROPAGAÇÃO <i>OUTDOOR-INDOOR</i>	42		
3.3	.1	MODELO PARTITION-BASED OUTDOOR-TO-INDOOR	43		
3.4	MO	DELOS DE PROPAGAÇÃO EM MACROCÉLULAS	43		
3.4	.1	MODELO DE TURIN	44		

	3.5	PROPAGAÇÃO EM CONSTRUÇÕES COMO GUIA DE ONDA	. 45		
	3.6	PERDA DE PENETRAÇÃO EM CONSTRUÇÕES	. 45		
4.	REI	DES NEURAIS ARTIFICIAIS	. 47		
	4.1	DEFINIÇÃO E PROPRIEDADES BÁSICAS	. 47		
	4.2	CONFIGURAÇÃO BÁSICA DO NEURÔNIO	. 49		
	4.3	FEEDBACK	. 52		
	4.4	TOPOLOGIAS DE REDE NEURAIS	53		
	4.5	PROCESSOS DE APRENDIZADO	. 54		
	4.6	ALGORITMO BACK-PROPAGATION	. 57		
5	CA	MPANHA DE MEDIÇÕES E PROCESSAMENTO DOS DADOS	. 60		
	5.1	DESCRIÇÃO DO AMBIENTES DE MEDIÇÕES	. 60		
	5.2	SETUP DE MEDIÇÕES	. 62		
	5.2.	1 ANTENAS DE TRANSMISSÃO E RECEPÇÃO	. 62		
	5.2.	2 GERADOR DE FUNÇÃO E ANALISADOR ESPECTRAL	. 64		
	5.2.	3 PARÂMETROS E PROCEDIMENTOS BÁSICOS DE MEDIÇÃO	65		
	5.3	TAXA DE AMOSTRAGEM	. 66		
	5.4	ESCOLHA E CONFIGURAÇÃO DA REDE NEURAL	. 68		
	5.5	CÁLCULO DOS MODELOS DE PREDIÇÃO	. 72		
6	AN	ÁLISE DAS MEDIÇÕES	. 75		
	6.1	ANÁLISE ESTATÍSTICA DOS DADOS	. 75		
	6.2	ANÁLISE DA VARIABILIDADE EM PEQUENA ESCALA DO SINAL	. 78		
	6.3	COMPARAÇÃO ENTRE PREDIÇÕES DE COBERTURA	. 83		
7	CO	NCLUSÕES	. 89		
8	BIB	LIOGRAFIA	. 92		
9	APÍ	ÈNDICE	. 96		
	9.1 <i>SCRIPT</i> PARA CALCULAR E COMPARAR AS DISTRIBUIÇÕES ESTATÍSTICAS AOS DADOS MEDIDOS				
	9.2	SCRIPT REDES NEURAIS ARTIFICIAIS	. 99		
	9.3	GRÁFICOS DAS FDPs POR ANDAR	101		

LISTA DE FIGURAS

Figura 2.1: Propagação sobre superfície plana	19
Figura 2.2: Fenômeno de Multipercursos.(Fonte: [1])	20
Figura 2.3: Difração sobre obstáculo. (Fonte: [1])	21
Figura 2.4: Reflexão e espalhamento em superfície semi-rugosa. (Fonte: [1])	22
Figura 2.5: Onda refratada do meio A para o meio B	22
Figura 2.6: Comportamento do sinal rádio móvel.(Fonte: [2])	24
Figura 2.7: Desvanecimento em pequena escala ao longo da distância percorrida. (Fonte: [1])	27
Figura 2.8: Função densidade de probabilidade (a); Função de distribuição Weibull (b)	32
Figura 3.1: Classificação dos modelos de predição	33
Figura 3.2: Distribuição dos edifícios segundo Walfisch-Ikegami.(Fonte: [4])	37
Figura 3.3: Cálculo do nível de sinal para o modelo WALFISCH-IKEGAMI.(Fonte: [10])	38
Figura 3.4: Local de referência e medição para perda de penetração.	44
Figura 4.1: (a) par de padrões lineares. (b) par de padrões não-lineares	47
Figura 4.2: Modelo básico de neurônio.	48
Figura 4.3: (a) Função Limiar (b) Função sigmoid	49
Figura 4.4: (a) Gráfico do fluxo de sinal de primeira ordem de duração infinita. (b) Aproximação do sistema	
feedforward. Fonte: [20]	51
Figura 4.5: (a) Rede Camada Única. (b) Rede multicamadas com camada escondida. (c) Rede Recorrente sen	n
ciclo de fedforward próprio e sem camada escondida. Fonte: [20]	52
Figura 4.6: Tipos de Máquinas de Aprendizado	53
Figura 4.7: Diagrama de blocos de aprendizado supervisionado.	54
Figura 4.8: Diagrama de blocos de aprendizado não supervisionado	54
Figura 4.9: Fluxo de Sinal através de um neurônio.	56
Figura 5.1: Vista aérea do enlace no Campus da UFF. (Fonte: Google Earth)	59
Figura 5.10: MSE da RNA 2 durante processo de aprendizado.	71
Figura 5.2: Cobertura antena transmissora no Bloco D da Engenharia.	60
Figura 5.3: Diagrama de irradiação da antena transmissora.	62
Figura 5.4: Curva da taxa de onda estacionária da antena transmissora	62
Figura 5.5: Antena omnidirecional receptora.	63
Figura 5.6: Diagrama unifilar da medição realizada	64
Figura 5.7: Redes neurais utilizadas (a) RNA 1 (b) RNA 2. (Fonte: Matlab [36])	68
Figura 5.8: Funções de ativação utilizadas. (Fonte: Matlab [37])	68
Figura 5.9: Erro quadrático médio (MSE) da RNA 1 durante processo de aprendizado	70
Figura 6.1: Diagrama de blocos relativo às operações sobre o sinal medido.	78
Figura 6.2: Sinal recebido em dBm no 2º andar do Bloco D de Engenharia da UFF.	78
Figura 6.3: Sinal recebido em dBm no 3º andar do Bloco D de Engenharia da UFF.	79
Figura 6.4: Sinal recebido em dBm no 4º andar do Bloco D de Engenharia da UFF.	79
Figura 6.5: Sinal recebido em dBm no 5º andar do Bloco D de Engenharia da UFF.	79
Figura 6.6: Nível de sinal recebido e métodos de predição aplicados no 2° andar	84
Figura 6.7: Nível de sinal recebido e métodos de predição aplicados no 3º andar	84
Figura 6.8: Nível de sinal recebido e métodos de predição aplicados no 4º andar	85
Figura 6.9: Nível de sinal recebido e métodos de predição aplicados no 5° andar	85

LISTA DE TABELAS

- Tabela 2.1. Bandas de Frequência.
- Tabela 3.1: Definição de tipos de célula.
- Tabela 3.2: Tipos de paredes para o modelo *multi-wall*.
- Tabela 3.3: Tabela 3.3: Resultados para coeficientes dos modelos de perda acima descritos para a frequência de 1800MHz. O ambiente denso um andar indica que Tx e Rx estão no mesmo andar, dois andares que Tx e Rx estão em andares adjacentes e múltiplos andares significa que Tx e Rx possuem dois ou mais andares de distância.

Tabela 5.1: Características básicas da Antena Transmissora.

Tabela 5.2: Parametrização utilizada no sistema de medição.

- Tabela 5.3: Parâmetros de Medição.
- Tabela 5.4: Obstruções por andar.
- Tabela 6.1: Cenários possíveis de classificação das amostras empíricas e teóricas.
- Tabela 6.2: Métrica D aplicada a todos os andares.
- Tabela 6.3: Valores utilizados por andar.
- Tabela 6.4: Parâmetros de entrada por método de predição.
- Tabela 6.5: Comparação de resultados entre os métodos de predição.

GLOSSÁRIO

- ANATEL Agência Nacional de Telecomunicações
- CRM Canal rádio móvel
- EiRP Equivalent isotropically radiated power
- ERB Estação radio base
- FDP Função densidade de probabilidade
- GSM Global System for Mobile Communications
- HF High Frequency
- ITU International Telecommunication Union
- LAM Linear atenuation model
- LOS Line of Sight
- NLOS Non Line of Sight
- LTE Long Term Evolution
- MLP Multilayer Perceptron
- MSE Mean-Squared Error
- OEM Onda eletromagnética
- **OFDM Orthogonal Frequency Division Multiplex**
- QCI QoS Class Identifier
- RNA Rede Neural Artificial
- THR Total Hit Rate
- UHF Ultra High Frequency
- VoLTE Voice over LTE
- UMTS Wide-Band Code-Division Multiple Access

Resumo

Este trabalho é composto de duas análises complementares originadas a partir de campanha de medições realizada em faixa estreita, na portadora de 768 MHz, com transmissão *outdoor rooftop* e recepção em ambiente *indoor* em edifício localizado a 112 metros de distância do transmissor. A primeira análise verifica o comportamento do canal rádio móvel em ambientes confinados, neste caso, em corredores. Aos dados obtidos das medições verifica-se a função densidade de probabilidade que melhor se ajusta à envoltória do sinal. A partir do erro encontrado, pôde-se observar que a distribuição de Rice com fator $K \gg$ 1, tendendo a uma gaussiana, foi a que apresentou melhor aproximação. Na análise seguinte, a *path loss* é obtida, empiricamente, e comparada aos modelos de propagação apropriados para ambiente *outdoor-to-indoor*. Além disso, duas redes neurais artificiais (RNA) do tipo *Multilayer Perceptron* (MLP) *backpropagation* foram usadas para determinar a precisão que é possível se obter neste tipo de predição. Duas métricas foram empregadas para encontrar qual dos distintos métodos apresentou a melhor aproximação, quando comparados aos valores reais: a métrica D e a *Total Hit Rate* (THR), esta com os limiares de -80 dBm e -70 dBm e conclui-se pela eficácia do emprego das redes neurais para melhoria da predição de cobertura.

Palavras-chave: Cobertura de sinal *indoor;* distribuições estatísticas; modelos de predição de sinal; redes neurais artificiais.

Abstract

This work consists in two complementary studies originated from a narrow band measurement campaign in 768 MHz carrier. The signal was transmitted from an outdoor rooftop and received in indoor environment, composed just by corridors, in a building located 112 meters far from the transmitter. In a first analysis, the behavior of the mobile radio channel is verified in confined environments. The data obtained from the measurements were used to obtain the probability density function which best fits the signal envelope. Based on D-Metric to calculate the error, Rice distribution with factor K »1, tending to a Gaussian, was the one which presented the smallest error and by consequence the best approximation. In the following analysis, the obtained path loss was compared with the appropriate propagation models for this channel. In addition, two artificial neural networks (ANN) Multilayer Perceptron (MLP) backpropagation type were used to determine the improvement that can be obtained in this type of prediction. Two metrics were used to find which of the different methods presented the smallest error, when compared to the measured values: metric D and Total Hit Rate (THR), with thresholds of -80 dBm and -70 dBm and concluded by accuracy of the use of neural networks to improve coverage prediction.

Keywords: Indoor signal coverage; statistical distributions; Signal prediction models; Artificial neural networks.

CAPÍTULO 1 INTRODUÇÃO

A comunicação entre pessoas sempre foi demanda essencial para o desenvolvimento de toda a sociedade. Sua evolução, apesar de bastante acelerada nas últimas duas décadas, parece ainda estar atrasada perante as demandas atuais. Mesmo com o grande aumento das taxas de dados, provenientes da quarta geração de telefonia móvel, com a utilização do sistema LTE (*Long Term Evolution*) e sua maior robustez com o emprego do OFDM (*Orthogonal Frequency Division Multiplex*), a demanda por novos serviços e melhor qualidade continua alta e em constante renovação. Como em todo nicho de tecnologia, novos recursos geram novos serviços e também criam novas demandas.

Nas comunicações móveis, o desenvolvimento também foi muito grande e é difícil dizer se as necessidades dos usuários foram responsáveis pela evolução tecnológica ou se foi a evolução em si, que alterou o comportamento dos usuários, tornando novos produtos e serviços oferecidos, em ferramentas relevantes nos tempos atuais. A combinação de *smartphones* de alto desempenho com conexões de alta velocidade, vem transformando a forma como as pessoas se comunicam, buscam informações e interagem. Neste contexto, o planejamento de rede de forma mais eficaz, a entrega de serviços com a maior qualidade possível e o desenvolvimento de novas funcionalidades são, sem dúvida, um diferencial para as operadoras de telefonia móvel e os desenvolvedores de tecnologia.

1.1 MOTIVAÇÃO

A motivação deste trabalho passa pelo entendimento do panorama atual das comunicações móveis no Brasil e no mundo. As operadoras no Brasil possuem, em 2017, redes GSM, UMTS e LTE ativas. O total de tráfego de voz e dados transportado no GSM já não apresenta aumento, enquanto o volume de dados no UMTS continua em expansão e o LTE segue com crescimento acelerado. Este ano, conforme ANATEL, está em transição a liberação da faixa de frequências de 700 MHz, que era utilizada pela TV analógica para o serviço de comunicação móvel. Esta faixa será utilizada pelo LTE e, com certeza, tornará possível atender a uma demanda reprimida bastante significativa. Neste contexto, o planejamento realizado da forma mais acertiva possível significa melhor atendimento ao cliente final e economia de recursos.

O panorama mundial envolve a entrada de novas tecnologias no mercado e tecnologias em desenvolvimento. Como exemplo, o VoLTE (Voz sobre o LTE), que está em plena ativação em diversos países. O serviço de dados no LTE requer QCI (identificador de classe de QoS) igual a 6, 7, 8 ou 9 de forma não garantida, enquanto o VoLTE requer CQI = 1 ou 2 durante a chamada, de forma garantida. Deste modo, é necessário garantir níveis de qualidade do sinal melhores que o considerado satisfatório para o serviço de dados, para que não ocorram quedas durante a ligação.

1.2 OBJETIVO

Este trabalho tem como objetivo o melhor entendimento do comportamento do canal rádio móvel na faixa de frequência de 768 MHz em ambiente *outdoor-to-indoor*. Deste modo, foi realizada campanha de medições, em que o sinal foi transmitido em ambiente aberto e recebido em corredores, no interior de edifício localizado a 112 m de distância. Em seguida, duas análises distintas foram realizadas: a estatística de variabilidade do sinal em faixa estreita

e um estudo comparativo entre métodos de predição de cobertura distintos, ambos identificando o melhor ajuste aos dados obtidos nas medições.

A primeira análise verifica o comportamento do canal rádio móvel em ambientes confinados, neste caso corredores. Os dados são, então, comparados às distribuições estatísticas de Rayleigh, Rice com fator *K* variável e gaussiana, a fim de descobrir qual se adapta melhor à envoltória do sinal. A partir da Métrica D, explicada no item 6.1, para cálculo do erro, pode-se observar que a distribuição de Rice com fator $K \gg 1$, tendendo a uma gaussiana, foi a que apresentou melhor aproximação.

O segundo estudo realiza a comparação entre os modelos de predição *Partition-Based Outdoor-to-indoor* e *Multi-Wall Cost* 231 e duas redes neurais artificiais (RNA1 e RNA2) do tipo MLP *backpropagation*. A Métrica D é utilizada para encontrar quais dos distintos modelos apresentaram o menor erro, em dB, quando comparados aos valores reais medidos. É utilizada, também, a métrica *Total Hit Rate* com dois limiares. Esta métrica é uma indicação de qualidade do modelo, uma vez que indica a porcentagem de amostras teóricas e experimentais que se aproximam a partir de determinado limite estipulado.

1.3 DESCRIÇÃO DOS CAPÍTULOS

Esta tese foi estruturada com embasamento teórico e desenvolvimento prático divididos de acordo com os capítulos descritos a seguir. No Capítulo 2 é mostrada a caracterização teórica da propagação de ondas eletromagnéticas, mecanismos de propagação, desvanecimento em pequena e grande escala e análise do canal em faixa estreita. O Capítulo 3 descreve a categorização dos modelos de predição, como são divididos em função do método de sua criação e de sua abrangência, de acordo com os distintos tipos de células existentes. O Capítulo 4 apresenta o embasamento teórico de Redes Neurais Artificiais e suas

funcionalidades utilizadas neste trabalho. O Capítulo 5 especifica todo o trabalho de campanha de medições, processamento dos dados capturados, configuração e treinamento das redes neurais utilizadas. O capítulo 6 apresenta os resultados obtidos a partir da caracterização faixa estreita do canal e do comparativo dos métodos de predição utilizados. Introduz as formas de comparação utilizadas para determinar a distribuição e o método de predição que obtiveram o melhor resultado. Já o Capítulo 7 apresenta a conclusão do trabalho a partir dos resultados obtidos, sua relevância para o mercado e sugestões de trabalhos futuros.

CAPÍTULO 2

TEORIA DA PROPAGAÇÃO DE ONDAS ELETROMAGNÉTICAS

Neste capítulo, será considerado todo o caminho percorrido pela onda eletromagnética (OEM), desde sua saída a partir da antena transmissora, até sua chegada à antena receptora. A tabela 2.1 mostra as diversas bandas de frequência e seus limites. Nesta dissertação, foram realizadas medições em frequência específica de UHF. Tal faixa possui frequências muito altas para propagação ionosférica, e sua comunicação ocorre por ondas diretas e ondas refletidas, portanto é importante considerar os diversos tipos de refração e reflexão no caminho.

Banda de Frequência	Faixa de Frequência
Extremely low frequency (ELF)	< 3 kHz
Very low frequency (VLF)	3-30 kHz
Low frequency (LF)	30-300 kHz
Medium frequency (MF)	300 kHz-3MHz
High frequency (HF)	3-30 MHz
Very high frequency (VHF)	30-300 MHz
Ultra high frequency (UHF)	300 MHz-3 GHz
Super high frequency (SHF)	3-30 GHz
Extra high frequency (EHF)	30-300 GHz

Tabela 2.1. Bandas de Frequência.

O meio percorrido pela OEM é definido como Canal Rádio. O termo "Rádio Móvel" é utilizado para situações onde o transmissor e/ou receptor são capazes de serem movidos [1].

À medida que a localização do receptor varia, também variam, de forma aleatória, as características do canal rádio móvel (CRM) pelo qual a OEM se propaga. Este canal pode ser caracterizado tanto em faixa larga como em faixa estreita, gerando resultados diversos. A

caracterização do CRM, assim como os mecanismos de propagação e seus efeitos são, brevemente, descritos a seguir.

2.1 MECANISMOS DE PROPAGAÇÃO

Os principais mecanismos de propagação vistos nas faixas de frequências utilizadas para sistemas de cobertura por células são: visibilidade, reflexão, difração e espalhamento. Entender e saber a função de cada um destes mecanismos é extremamente importante, pois estes determinam a atenuação pela propagação no enlace, logo, o valor médio do sinal no receptor.

2.1.1 VISADA DIRETA

É o tipo de propagação mais básico, onde, tanto o emissor quanto o receptor estão com ausência de obstruções ao longo do caminho (Line of Sight - LOS) e sem perturbações na recepção do sinal.

Para casos em visada, a distância não ultrapassa algumas dezenas de quilômetros, logo é possível considerar a propagação em espaço livre, negligenciando a curvatura terrestre $(d>>h_T e d \gg h_R)$ e a possível reflexão no solo, e seguindo a equação (2.1).

$$\frac{P_R}{P_T} = G_T G_R \left(\frac{h_T h_R}{d^2}\right)^2 \tag{2.1}$$

onde P_R é a potência recebida, P_T é a potência transmitida, G_T e G_R são os ganhos das antenas transmissora e receptora, respectivamente, $h_T e h_R$ são a altura da antena transmissora e da antena receptora, respectivamente, e *d* a distância entre a antena transmissora T e a antena receptora R [2].

2.1.2 REFLEXÃO

O fenômeno da reflexão ocorre quando uma OEM incide sob um objeto que possui dimensões muito grandes em comparação com o comprimento da onda que se propaga [3], por exemplo, um terreno plano, um lago ou o mar. Caso a superfície seja um dielétrico perfeito parte da energia é transmitida para o segundo meio e parte é refletida, caso seja um condutor perfeito, então toda a energia é refletida. Numa ligação rádio, a intensidade da onda refletida é função da rugosidade da superfície refletora, frequência da onda, ângulo de incidência sobre o solo e tipo de polarização da onda.

A reflexão pode gerar mudança de fase e atraso. Dependendo da fase e do atraso, a onda pode compor o sinal recebido desde uma total concordância de fase com a onda direta (soma das amplitudes dos sinais) até a de oposição de fase (subtração das amplitudes dos sinais). A Figura 2.1 mostra as variáveis envolvidas na reflexão em terra plana.



Figura 2.1: Propagação sobre superfície plana.

Outro efeito causado pela reflexão das OEMs são os multipercursos relacionados aos diversos sinais que chegam ao receptor defasados do transmitido. Este efeito tem grande serventia para os sistemas móveis, desde que as ondas cheguem ao terminal móvel em concordância de fase. Assim, haverá um ganho no nível do sinal. Este fenômeno possibilita a

comunicação de uma estação rádio base com o terminal móvel, mesmo que não haja linha de visada entre os dois tal qual a figura 2.2.



Figura 2.2: Fenômeno de Multipercursos.(Fonte: [1])

2.1.3 DIFRAÇÃO

A difração permite que sinais de rádio se propaguem ao redor da superfície curva da terrra, além do horizonte e por trás de obstruções [3]. Conforme a figura 2.3, é normal pensar que, após a frente de onda AA' deparar-se com um obstáculo da mesma ordem de grandeza do comprimento de onda, apenas a frente de onda CC' existiria.



Figura 2.3: Difração sobre obstáculo. (Fonte: [1])

O fenômeno de difração pode ser explicado pelo princípio de Huygens, que afirma que todos os pontos em uma frente de onda podem ser considerados como fontes pontuais para produção de ondas secundárias, e essas ondas secundárias se combinam para formar uma nova frente de onda na direção da propagação.

2.1.4 ESPALHAMENTO

O espalhamento ocorre quando a OEM incide sobre uma superfície rugosa, ocorra reflexão difusa e a onda se espalhe em direções diversas. A definição de rugosidade é dada segundo o critério de rugosidade de Rayleigh. Se a rugosidade do solo, representado por σ , que é o desvio padrão das alturas médias das irregularidades, for tal que $\sigma < \frac{\lambda}{8sena}$, então a superfície é dita lisa, onde λ é o comprimento de onda e α é o ângulo de incidência no solo, conforme Figura 2.1. Caso contrário, é dita rugosa. Quando consideramos a reflexão da onda no solo, chamamos de especular quando a terra é considerada lisa e difusa, quando considerada rugosa.

As rugosidades da superfície fazem com que haja inúmeros ângulos de incidência, tornando a distribuição desordenada, gerando o espalhamento da energia, exemplificado pela Figura 2.4. Este efeito causa a diminuição da potência total que chegada ao receptor. Quando a superfície é rugosa, a refletida pode ser desprezada na antena receptora.



Figura 2.4: Espalhamento em superfície semi-rugosa. (Fonte: Google)

2.1.5 REFRAÇÃO

Ocorre quando a OEM passa de um meio para outro que possua índice de refração distinto, variando a velocidade e a direção de propagação. Estes desvios podem acarretar em degradação do enlace podendo, inclusive, fazer com que o sinal não chegue ao destino. A Figura 2.5 ilustra uma OEM que, ao incidir na fronteira entre os meios A menos denso e B mais denso, tem parte de sua energia refletida e parte refratada. A direção da onda refratada aproxima-se da normal com a fronteira uma vez que sua velocidade é reduzida.



Figura 2.5: Onda refratada do meio A para o meio B.

Os enlaces de rádio são realizados na camada mais baixa da atmosfera, a Troposfera, onde a temperatura tende a decrescer com o incremento da altitude. Logo após a Troposfera, está a Estratosfera, onde a temperatura tende a permanecer constante com a altura. A fronteira entre estas camadas chama-se Tropopausa, sua altura em relação à Terra varia de 9 km nos Polos a 17 km no Equador. A mesma pode variar também de acordo com fenômenos naturais como chuvas e ciclones. Este breve entendimento sobre a atmosfera é importante, pois em frequências acima de 30 MHz estas características podem acarretar em: flutuações localizadas no índice de refração, variações abruptas do índice de refração de acordo com a altura e o fenômeno de dutos.

2.1.6 ABSORÇÃO

Assim como os outros tipos de ondas, a OEM também está sujeita a esse fenômeno, segundo o qual o meio diminui de forma irreversível a energia da onda, fazendo com que sua amplitude e alcance sejam reduzidos. Ao propagar-se, há sempre atrito com o ar, montanhas, construções e diversos obstáculos. Consequentemente, há perda de energia, por isso há um limite de cobertura.

2.2 EFEITOS DA PROPAGAÇÃO

O CRM real apresenta variações temporais aleatórias uma vez que está sujeito aos mecanismos descritos na seção anterior, juntamente com a mobilidade. Pode ser caracterizado em faixa estreita ou em faixa larga, dependendo do resultado final desejado.

2.2.1 CARACTERIZAÇÃO EM FAIXA ESTREITA

Na caracterização em faixa estreita é enviado um sinal s(t) como uma onda contínua em função do tempo, que possui um impulso como resposta em frequência. A Eq. (2.2) demonstra o sinal transmitido nos domínios do tempo e da frequência.

$$s(t) = \cos \omega_c t \tag{2.2a}$$

$$F(\cos \omega_c t) = \pi \left[\delta(\omega + \omega_c) + (\omega - \omega_c) \right]$$
(2.2b)

Através das medições em faixa estreita, é possivel analisar a variação espacial do sinal em pequena e grande escala, a queda da potência com a distância (*path loss*), o deslocamento de frequência Doppler e a despolarização sofrida pela OEM, entretanto, este tipo de análise não fornece nem a magnitude nem o retardo de fase dos percursos de maneira individual.

Nas medições em faixa estreita o nível de sinal é medido a cada instante, onde o receptor se desloca com velocidade constante v fazendo com que a distância esteja diretamente relacionada com o tempo. O processamento de tais medidas gera um gráfico que retrata o comportamento do sinal, conforme é visto na Figura 2.6.



Figura 2.6: Comportamento do sinal rádio móvel.

2.2.2 PERDA DE PERCURSO

Dentre as perdas sofridas por um sinalem propagação, a perda no espaço livre está sempre presente. É tomada em visada, onde a antena transmissora está localizada em uma área remota da terra e sem obstruções até a antena receptora, de modo que haja somente o sinal direto. Assim, a relação entre a potência recebida P_R e a potência transmitida P_T é descrita pela equação (2.1), aqui reescrita como (2.3), onde o comprimento de onda, λ , está substituído por *c/f*, sendo *c* a velocidade de propagação da onda e *f*, a frequência da onda.

$$\frac{P_R}{P_T} = G_T G_R \left(\frac{c}{4\pi f d}\right)^2 \tag{2.3}$$

Conforme observado por Molisch [4] e diversos autores, é mais útil para cálculos, utilizar a fórmula de Friis em escala logarítimica conforme equação (2.4).

$$P_{RX \vee dBm} = P_{TX \vee dBm} + G_{TX \vee dB} + G_{RX \vee dB} + 20 \log\left(\frac{\lambda}{4\pi d}\right)$$
(2.4)

Outro modo para determinar P_R é através da potência média de referência, P_{RM} , que é medida a uma distância de referência d_0 . É importante que P_{RM} esteja fora da região de campo

próximo da antena transmissora. Tem-se, então, a equação (2.5) em que *n* varia de acordo com as condições estruturais da região onde a comunicação se estabelece.

$$P_{R}(d) = P_{RM}(d_{0}) - 10.\log\left(\frac{d}{d_{0}}\right)^{n}$$
(2.5)

2.2.4 DESVANECIMENTO EM GRANDE ESCALA

O desvanecimento em grande escala é o fenômeno que ocorre à medida que o receptor se afasta do transmissor por grandes distâncias e, deste modo, a intensidade do sinal diminui de forma gradativa [5]. Esta diminuição ocorre sobre muitos comprimentos de onda da portadora.

Como o deslocamento do móvel em relação ao tamanho dos objetos é relativamente pequeno, as mudanças ocorrem lentamente. O sinal recebido passa por muitos objetos diferentes, sofrendo atenuações distintas, sendo assim, a potência recebida é formada pela soma dos fatores de transmissão de todos os objetos. O desvanecimento em grande escala é, usualmente, modelado por uma distribuição log-normal com desvio padrão típico, em um ambiente celular, no entorno de 8 dB [6]. Com o número de fatores elevado, o teorema do Limite Central diz que a distribuição da soma se aproxima de uma Gaussiana.

• DISTRIBUIÇÃO LOG-NORMAL

Para a distribuição Log-Normal é considerada a atenuação (α_i) e a espessura da iésima obstrução (Δr_i). Leva-se em consideração a amplitude da onda antes (E_0) e depois de passar pelos bloqueios (E_n).

$$E_n = E_0 e^{\left(-\sum_{i=1}^n \alpha_i \Delta r_i\right)} \tag{2.6}$$

Considera-se o número de obstruções bastante elevado, tal que seja possível fazer $n \rightarrow \infty$. A distribuição lognormal é definida pela equação 2.7.

$$f(x) = \frac{1}{x\sigma\sqrt{2\pi}} e^{\left[\frac{-(\ln(x)-\mu)^2}{2\sigma^2}\right]}$$
(2.7)

onde x é a variável aleatória, μ é a média de x, σ^2 a variância de x e σ o desvio padrão de x.

2.2.5 DESVANECIMENTO EM PEQUENA ESCALA

É considerado desvanecimento em pequena escala a alteração do nível de sinal recebido à medida que o receptor percorre pequenas distâncias, de até meio comprimento de onda, semelhante à figura 2.7. Para uma frequência de 750 MHz e sendo a velocidade de propagação igual à velocidade da luz, *c*, em menos de 0,5 m já é possível verificar variação. Isso ocorre quando a resposta ao impulso muda rapidamente com a duração de símbolo.



Figura 2.7: Desvanecimento em pequena escala ao longo da distância percorrida.

(Fonte: [1])

Este tipo de desvanecimento tem caráter aleatório, uma vez que tem como causadores os fenômenos de reflexão, difração e espalhamento. O sinal recebido é formado pelo somatório dos múltiplos percursos. Dependendo da fase com que estes chegam num determinado instante, pode-se ter uma soma construtiva ou destrutiva. Em geral, a variabilidade em pequena escala do sinal apresenta comportamento estatístico, que pode ser representado por uma função densidade de probabilidade Rayleigh, Rice ou Nakagami-m.

• DISTRIBUIÇÃO RAYLEIGH

A distribuição Rayleigh é característica da envoltória do sinal formada por um número grande de multipercursos chegando com fases diversas no receptor. As componentes apresentam níveis próximos de potência, não havendo um raio forte de visada.

Considera-se uma portadora *s* descrita de acordo com a equação (2.8).

$$s = ae^{jw_0 t} \tag{2.8}$$

onde w_0 é a sua frequência angular e *a* é a sua amplitude.

Considerando a_i como a amplitude e θ_i como a fase da *i*-ésima onda espalhada, o sinal obtido pelo receptor móvel (S_r) é o resultado da soma de *n* ondas espalhadas conforme (2.9).

$$S_r = \sum_{i=1}^n a_i e^{[j(w_0 t + \theta_i)]}$$
(2.9)

que é equivalente a

$$S_r = re^{[j(w_0 t + \theta_i)]} \tag{2.10}$$

$$re^{j\theta} = \sum_{i=1}^{n} a_i e^{j\theta_i} \tag{2.11}$$

Tem-se, também:

$$re^{j\theta} = \sum_{i=1}^{n} a_i \cos \theta_i + \sum_{i=1}^{n} ja_i \sin \theta_i \triangleq x + jy$$
(2.12)

Logo,

$$x \triangleq \sum_{i=1}^{n} a_i \cos\theta_i \text{ e } y \triangleq \sum_{i=1}^{n} a_i \sin\theta_i$$
(2.13)

onde

$$\begin{array}{c} r^{2} = x^{2} + y^{2} \\ x = r \cos \theta \\ y = r s e n \theta \end{array} \right\}$$

$$(2.14)$$

Considerando *n* muito grande, as amplitudes individuais a_i aleatórias e a fase θ_i com distribuição uniforme, pode-se assumir que *x* e *y* são ambas variáveis gaussianas com média igual a zero e variâncias iguais a $\sigma_x^2 = \sigma_y^2 \triangleq \sigma_r^2$, portanto, suas funções densidade de probabilidade são dadas de acordo com a expressão (2.15).

$$p(z) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\left(\frac{z^2}{2\sigma_r^2}\right)}$$
(2.15)

onde z = x ou z = y, como requerido.

Tendo como premissa que x e y são variáveis aleatórias gaussianas independentes de mesmo desvio padrão, então se pode considerar a distribuição de probabilidade conjunta, p(x, y) como a expressão (2.16):

$$p(x,y) = p(x)p(y) = \frac{1}{2\pi\sigma_r^2} e^{-\left(\frac{x^2+y^2}{2\sigma_r^2}\right)}$$
(2.16)

A partir de p(x, y), pode ser escrita a função $p(r, \theta)$:

$$p(r,\theta) = |J|p(x,y) \tag{2.17}$$

onde J representa o Jacobiano das transformações de x e y em r e θ . A partir das igualdades descritas em (2.14), obtém-se J = r.

$$J \triangleq \begin{vmatrix} \frac{\partial x}{\partial r} & \frac{\partial x}{\partial \theta} \\ \frac{\partial y}{\partial r} & \frac{\partial y}{\partial \theta} \end{vmatrix}$$
(2.18)

Substituindo *J* por *r* em (2.17), tem-se a função distribuição de probabilidade conjunta em função de *r* e θ :

$$p(r,\theta) = \frac{r}{2\pi\sigma_r^2} e^{-\left(\frac{x^2+y^2}{2\sigma_r^2}\right)}$$
(2.19)

A densidade p(r) é obtida através da média de $p(r, \theta)$ na faixa de variação de θ :

$$p(r) = \int_0^{2\pi} p(r,\theta) d\theta \tag{2.20}$$

Logo,

$$p(r) = \begin{cases} r\sigma_r^2 e^{\frac{-r^2}{2\sigma_r^2}}, \text{ para } r \ge 0\\ ou\\ 0 \text{ para outros valores} \end{cases}$$
(2.21)

onde r é a envoltória do sinal e σ_r^2 é a variância das componentes em fase e em quadratura que compõem o sinal S_r . Este modelo é relativamente simples de se trabalhar, pois é função apenas do parâmetro σ_r . p(r) que representa a f.d.p Rayleigh da envoltória do sinal, que é composta de dois processos gaussianos em quadratura.

• DISTRIBUIÇÃO RICE

A f.d.p. Rice também pode representar estatisticamente o sinal de variação rápida, porém, diferentemente de Rayleigh, há pelo menos uma componente de potência maior que as demais. Esta pode ser caracterizada pelo raio em linha de visada ou por um multipercurso que chegue com maior potência.

Para o sinal resultante S_r , este será caracterizado pela soma dos *n* multipercursos e pela onda direta, sendo modelado pela expressão (2.22).

$$S_r = \underbrace{re^{(jw_0t+\theta)}}_{componentes} + \underbrace{ae^{(jw_0t)}}_{componente \ dominante}$$
(2.22)

De acordo com a equação (2.22) pode-se observar que caso *a* seja nulo, a distribuição Rice torna-se a distribuição Rayleigh, pois não há uma componente dominante do sinal.

Após desenvolvimento algébrico, chega-se à f.d.p da variável de envoltória r [6], em função de $ae \sigma_r^2$:

$$p(r) = \frac{r}{\sigma_r^2} e^{\left(\frac{-r^2 + a^2}{2\sigma_r^2}\right) I_0\left(\frac{ar}{\sigma_r^2}\right)}$$
(2.23)

onde *r* representa a envoltória do sinal, $\frac{a^2}{2}$ a potência da onda recebida em linha de visada, σ_r^2 a média da potência do sinal da envoltória e $I_0(x) = \frac{1}{2\pi} \int_0^{2\pi} e^{x\cos\theta} d\theta$ é a função de Bessel modificada de ordem zero.

Empregando o fator K como a relação entre a potência da componente dominante com a potência das componentes de multipercurso, segundo a equação (2.24).

$$K = \frac{a^2}{2\sigma_r^2} \tag{2.24}$$

A distribuição Rice tende a de Rayleigh quando K apresenta valores pequenos, em geral menores que 1, o que ocorre quando a contribuição do raio direto não é significativa. Tende à gaussiana quando K apresenta valores bem maiores que 1, causado normalmente por obstrução do enlace.

• DISTRIBUIÇÃO NAKAGAMI-M

Assemelha-se à distribuição Rayleigh, pois também descreve flutuações provenientes de sinais com desvanecimento. Todavia, de forma mais abrangente, pode modelar variações mais severas como as observadas por Nakagami em medições HF em um canal ionosférico. Logo, para esta distribuição tem-se a f.d.p da equação (2.25).

$$p(r) = \frac{2}{\Gamma(m)} \left(\frac{m}{\alpha}\right)^m r^{2m-1} e^{\frac{-mr^2}{\alpha}}$$
(2.25)

onde Ω é definido como:

$$\Omega = E(r^2) \tag{2.26}$$

 $\Gamma(m)$ é a função gama, definida como:

$$\Gamma(m) = \int_0^\infty x^{m-1} e^{-x} dx$$
 (2.27)

E m é o fator de desvanecimento definido por:

$$m = \frac{\Omega^2}{E[(r^2 - \Omega)^2]}, m \ge \frac{1}{2}$$
(2.28)

Os parâmetros Ω e *m* são fatores de ajuste estatístico da distribuição, necessários devido aos efeitos do desvanecimento do canal. Enquanto a distribuição Rayleigh apresenta apenas um parâmetro, a utilização de duas variáveis agrega maior flexibilidade e precisão na modelagem do canal.

• DISTRIBUIÇÃO WEIBULL

Esta distribuição também pode ser empregada na caracterização do desvanecimento e é dada de acordo com a equação (2.29).

$$p_{\alpha}(\alpha) = c \left(\frac{\Gamma\left(1+\frac{2}{c}\right)}{\Omega}\right)^{\frac{c}{2}} \alpha^{c-1} e^{\left[-\left(\frac{\alpha^{2}}{\Omega}\Gamma\left(1+\frac{2}{c}\right)\right)^{\frac{c}{2}}\right]}, \alpha \ge 0$$
(2.29)

Assim como a distribuição de Rice, a de Weibull transforma-se na distribuição de Rayleigh dependendo do valor de sua variável. Para isto ocorrer c deve ser igual a dois. Quando c = 1 tem-se uma distribuição exponencial. A figura 2.8 mostra tal distribuição.



Figura 2.8: (a)Função densidade de probabilidade; (b)Função de distribuição Weibull.

CAPÍTULO 3

MODELOS DE PREDIÇÃO DE PROPAGAÇÃO

Para se implementar um sistema rádio móvel, modelos de predição são necessários para determinar a cobertura do sinal de propagação em determinado local e podem ser classificados de acordo com a figura 3.1.



Figura 3.1: Classificação dos modelos de predição.

• MODELOS EMPÍRICOS

São obtidos a partir de medidas efetuadas em um determinado ambiente, em faixas específicas de frequência e com dados de entrada bem definidos. A partir dos resultados obtidos, criam-se expressões que fornecem o valor médio da atenuação no local onde ocorreram as medidas. São consideradas as variações estatísticas de nível médio do sinal e a morfologia do local. Esses modelos apresentam relativa facilidade, além de um fácil processamento computacional e produzem bons resultados para regiões com características semelhantes as das medições que os geraram.

Há modelos que fazem certas adaptações nas expressões, para que se possa usá-los em áreas de características diferentes.

• MODELOS SEMI-EMPÍRICOS

Também conhecidos como semi-determinísticos. De maneira semelhante aos modelos empíricos, são obtidos através de campanhas de medições em campo, porém suas equações levam em consideração a teoria e os modelos canônicos de propagação.

Alguns modelos se baseiam na atenuação em espaço livre (Fórmula de Friis) dependendo, assim, da distância e da frequência usada. Diferem entre si, no uso da constante aditiva, que é obtida empiricamente. Sendo assim, para cada região há um valor para esta constante.

• MODELOS DETERMINÍSTICOS

São baseados em determinadas formulações da teoria eletromagnética, como a teoria geométrica da difração ou a teoria uniforme da difração [7]. Incluem fórmulas para atenuação no espaço livre e formas de se considerar os efeitos do terreno e rádio clima.

Usa-se, normalmente, a técnica de traçado de raios para mapear a propagação das OEMs no ambiente. Todos os fatores considerados, como raio direto, reflexões e difrações, são computados através de algum tratamento dado às equações exatas.

Tais modelos são bastante confiáveis, já que têm como base a teoria eletromagnética, portanto, podendo ser aplicados em variados tipos de ambientes. Basta apenas uma descrição geométrica detalhada do ambiente. Como desvantagem, estes modelos demandam muito tempo de processamento computacional e são de difícil implementação. Dependendo da precisão desejada, muitos multipercursos terão que ser tomados.

Classificações adicionais que inserem maiores restrições aos ambientes em que determinado modelo pode ser utilizado, também são comumente utilizadas. Pode-se dividir os modelos de predição de acordo com o tipo de célula, segundo a tabela 3.1. Conforme será visto nos itens subsequentes, as características do sistema utilizado na sondagem deste trabalho aproxima-se à classificação *pico-cell* x *in-house*. O qual se aplica principalmente a células *indoor* ou células muito pequenas e sua antena transmissora é montada *indoor* ou muito abaixo do nível do topo dos edifícios (*roof-top*). A diferença está na antema transmissora que, para esta campanha de medições, foi instalada ao nível do terraço dos demais edifícios.

Tipo de Célula	Raio típico (km)	Posição típica da antena transmissora
Macro célula	1-30	<i>outdoor</i> ; montada ao nível do terraço dos edifícios (<i>roof-top</i>), acima altura das construções ao seu redor
Pequena Macro célula	0,5-3	<i>outdoor</i> ; montada ao nível do terraço dos edifícios (<i>roof-to</i> p), algumas construções ao seu redor possuem alturas maiores
Micro célula	até 1	<i>outdoor</i> ; montada abaixo do nível do terraço dos edifícios (<i>roof-top</i>)

Tabela 3.1: Definição de tipos de célula.
3.1 MODELOS DE PROPAGAÇÃO EM MICROCÉLULAS

O estudo de microcélulas é de grande importância, principalmente para regiões urbanas. A transmissão via rádio neste tipo de ambiente está sujeita a grande quantidade de multipercursos.

O critério mais comum para definição de uma microcélula é a altura em que está instalada a antena transmissora. Esta deve estar posicionada abaixo da altura média das construções em seu entorno, o que limita seu alcance em torno de até 1 km. Os modelos de propagação para este tipo de célula são baseados em uma abordagem determinística através da análise dos raios ou por técnicas de traçado de raios.

A modelagem pode ser feita em duas ou três dimensões. Por ser mais simples e exigir menos processamento, foram criados inúmeros modelos em duas dimensões. Os modelos bidimensionais podem considerar as construções ao redor do transmissor como de altura infinita e então a OEM propaga-se apenas no entorno das mesmas. Caso as construções sejam baixas, deve-se considerar, também, a propagação sobre o teto. Os modelos tridimensionais permitem uma abordagem bem específica da perda no percurso e do espalhamento do sinal.

3.1.1 COST 231-WALFISCH-IKEGAMI MODEL

Este modelo é o resultado da junção dos modelos criados por Walfisch [8] e Ikegami [9], então formando o modelo COST 231-WALFISCH-IKEGAMI, que consta no Report 567-4 da ITU-R. Pode ser utilizado tanto para estações rádio base (ERBs) com antenas acima do topo dos edifícios quanto para antenas mais baixas, contudo, são obtidos resultados piores em casos onde a antenna se localiza próxima ou abaixo dos topos dos edifícios ao seu redor. Este modelo é restrito a regiões urbanas e planas. Considera, em seus cálculos, a altura das construções, assim como a distância entre elas e a largura das ruas. Supõe distribuição uniforme dos edifícios e espaçamento uniforme entre eles, conforme figura 3.2.



Figura 3.2: Distribuição dos edifícios segundo Walfisch-Ikegami.(Fonte: [4])

A riqueza de parâmetros a serem considerados para uma melhor aproximação dos valores medidos faz com que o modelo possua uma série de restrições que seguem elencadas abaixo:

- 800 MHz \leq f \leq 2000 MHz
- $4 \text{ m} \le h_b \le 50 \text{ m}$
- $1 \text{ m} \le h_m \le 3 \text{ m}$
- $0.2 \text{ km} \le d \le 5 \text{ km}$

onde h_b é a altura da estação base e h_m é a altura da estação móvel.

Uma vez atendidas as regras acima, o cálculo da atenuação entre prédios ao longo da rua é dado conforme as equações (3.1) e (3.2). Com linha de visada:

$$L_b = 42.6 + 26.\log d + 20.\log f, \text{ para } d \ge 20 \text{ m}$$
(3.1)

No caso sem linha de visada:

$$L_{b} = \begin{cases} L_{0} + L_{rts+} L_{msd} \\ L_{0}, se \ L_{rts+} L_{msd} < 0 \end{cases}$$
(3.2)

onde L_o é a perda no espaço livre, L_{rts} é a perda por difração e espalhamento do campo, do topo do último edifício, antes do móvel, até o móvel e L_{msd} é a perda por difração múltipla, nos topos dos edifícios.



Figura 3.3: Cálculo do nível de sinal para o modelo WALFISCH-IKEGAMI.(Fonte: [10])

Os cálculos de L_o , L_{rts} e L_{msd} são efetuados através de expressões próprias deste modelo e que levam em conta parâmetros bem específicos como o ângulo entre Tx e Rx e o eixo entre o último prédio e a estação móvel. Fatores de correção consideram a dependência entre a perda por difração múltipla, a distância e a frequência (K_f) e o aumento da perda quando as antenas estão a uma altura menor que os edifícios.

A variável K_f cresce com a frequência, acarretando em perda maior de sinal. Isso porque o comprimento de onda λ diminui à medida que a frequência aumenta, tornando os obstáculos eletricamente maiores. Esse fator é maior para zonas mais urbanas, onde predomina a grande quantidade de edifícios de alturas variadas.

3.2 MODELOS DE PROPAGAÇÃO INDOOR

Os modelos de propagação *indoor* dividem-se em quatro grupos: modelos de faixa estreita empíricos, modelos de faixa larga empíricos, modelos variantes no tempo e modelos determinísticos. Modelos de faixa estreita empíricos são expressos de forma simples através de equações matemáticas, que retornam a perda de propagação. Estas equações são obtidas através da adequação do modelo pelas medidas obtidas. Modelos de faixa larga empíricos são expressos por tabelas que listam a média de espalhamento de retardo e perfis de potência. Modelos variantes no tempo são utilizados para estimativas de Doppler no sinal recebido. Modelos determinísticos são métodos de cálculo que simulam a propagação e as perdas das ondas de rádio. Na sequência, dois modelos faixa estreita do COST 231 são descritos.

3.2.1 MODELO MULTI-WALL

Este modelo [11] pode ser descrito de acordo com a eq. (3.3).

$$L = L_{FS} + L_c + \sum_{i=1}^{l} k_{wi} L_{wi} + k_f \left[\frac{k_f + 2}{k_f + 1} - b \right] L_f$$
(3.3)

onde L_{FS} representa a perda no espaço livre entre o transmissor e o receptor; L_c , a constante de perda; L_f , a perda entre andares; k_{wi} , o número de paredes do tipo i penetradas; k_f , o número de pisos penetrados; L_{wi} , a perda por parede do tipo i; *b*, o parâmetro empírico e *I*, o número de tipos de paredes.

A constante de perda L_c é obtida quando são determidadas as perdas de parede por meio do resultado de medições, através de regressão linear múltipla. Normalmente possui valores próximos a zero. A quantidade de tipos de paredes varia de acordo com a construção. Para fins práticos, é interessante que haja poucos tipos. Este modelo propõe apenas dois tipos de paredes, de acordo com as especificações da tabela 3.2.

Tabela 3.2: Tipos de paredes para o modelo multi-wall.

Tipo de parede	Descrição	
Parede leve (Lw1)	Paredes de plástico ou com espessura < 10 cm, concreto leve.	
Parede pesada (Lw2)	Paredes com espessura > 10 cm, normalmente de concreto ou tijolo.	

3.2.2 MODELO DE ATENUAÇÃO LINEAR

O *linear atenuation model* (LAM) assume que o excesso de perda, em dB, é linearmente dependente da distância, em metros, de acordo com o coeficiente de atenuação α (dB/m).

$$L = L_{FS} + \alpha. d \tag{3.4}$$

A tabela 3.3 ajuda a otimizar os coeficientes dos modelos apresentados. Esta foi criada a partir de medições realizadas por grupos e empresas distintos, em 5 construções diferentes, nas frequências de 900 MHz e 1800 MHz e reunidas pelo grupo COST 231 [11]. No mesmo estudo, é explicada a dependência entre os coeficientes e a frequência, onde a faixa de 900 MHz possui atenuação, em média 1,5 dB menor para paredes leves e 3,5 dB menor para pisos do que na faixa de 1800 MHz. Estes valores estão de acordo com estudo realizado pela Ericsson [12], que apontou atenuação de 2,1 dB para paredes leves.

Tabela 3.3: Resultados para coeficientes dos modelos de perda acima descritos para a frequência de 1800MHz. O ambiente denso um andar indica que Tx e Rx estão no mesmo andar, dois andares que Tx e Rx estão em andares adjacentes e múltiplos andares significa que Tx e Rx possuem dois ou mais andares de distância.

Ambiente	М	ulti-wall mo	Modelo Linear (LAM)		
	Lwl [dB]	[dB] Lw2 [dB] Lf [dB] b		b	а
Denso					
Um andar					0.62
Dois	2.4	6.0	10.0	0.46	0.02
andares	3,4	0,9	18,3	0,40	2.0
Multiplos					2.8
andares					
Aberto	3,4	6,9	18,3	0,46	0,22
Grande	3,4	6,9	18,3	0,46	
Corredor	3,4	6,9	18,3	0,46	

3.3 MODELO DE PROPAGAÇÃO OUTDOOR-INDOOR

Ao modelar o canal *outdoor-to-indoor*, os principais problemas são a perda de penetração em construções (*entry loss*) e o atraso de espalhamento da energia recebida. A perda de penetração é a mais crítica, uma vez que a atenuação pode ser bastante severa, enquanto o atraso de espalhamento é da ordem de dezenas de nanosegundos (ns). Os raios da OEM secundários, produzidos por reflexão e difração em outras construções, antes de

penetrar o edifício em que se encontra a antena receptora, serão, em geral, desprezíveis em relação ao sinal que ilumina de forma direta o edifício [13].

3.3.1 MODELO PARTITION-BASED OUTDOOR-TO-INDOOR

Modelo criado por Rappaport, Durgin e Xu [14], em 1998, a partir de campanha de medições realizada dentro e no entorno de três casas e dois galpões de árvores em região de característica residencial suburbana. Durante as medições, o transmissor foi fixado em ambiente aberto a 5,5 m de altura, a uma distância variável do receptor, entre 30 e 210 m. Após mais de 276.000 medições de potência, o modelo *Partition-Based Outdoor-to-indoor* chegou à descrição matemática dada pela equação (3.5), onde à equação do espaço livre é adicionado o termo de perdas.

$$P_{R}(d) = P_{T} + G_{T} + G_{R} + 20.\log\left(\frac{\lambda}{4\pi d}\right) - \sum_{i=1}^{N} X_{i}$$
(3.5)

onde X_i é a atenuação da *i*-ésima obstrução no enlace Tx-Rx, independente de ser *indoor* ou *outdoor*.

3.4 MODELOS DE PROPAGAÇÃO EM MACROCÉLULAS

Modelos para predição em macrocélulas possuem bastante importância por sua grande abrangência, com grande raio de alcance (1-30 km) devido ao posicionamento da antena transmissora acima da altura média das construções ao seu redor. São baseados, principalmente, nas informações de topologia da região e altura média das construções. São importantes os modelos de Walfisch-Bertoni [15], Ikegami [16], Hata [17] e Turin [18], dentre as abordagens mais conhecidas.

3.4.1 MODELO DE TURIN

Modelo de propagação multipercurso criado a partir de campanha de medições na área urbana de Turin. Amostras foram enviadas a partir de um transmissor fixo nas frequências de 488, 1280 e 2920 MHz e coletadas por uma VAN em movimento constante. Os testes foram realizados em quatro áreas distintas, com características bastante semelhantes. Foi então considerado um modelo matemático preliminar, que após análise das medidas coletadas, pode então ser adequado conforme a Eq. 3.6. Sabendo que o sinal enviado foi $R\{s(t)e^{-i\omega_0t}\}, t \in$ $(-\infty, \infty)$ e o sinal recebido $\{\rho(t)e^{-i\omega_0t}\}, t \in (-\infty, \infty)$.

$$\rho(t) = \sum_{k=0}^{\infty} S^{f_k} a_k s(t - t_k) e^{i\theta_k} + n(t)$$
(3.6)

onden(.) é o ruído branco Gaussiano; $20log_{10}a_k$ é normal com média μ_k e variância σ_k^2 ; $20log_{10}S$ é normal com média μ e variância σ^2 , θ_k é distribuído uniformemente; $\{t_k - t_0\}_1^\infty$ é uma sequencia de Poisson modificada com taxa média de chegada determinada por curvas empíricas de probabilidade de ocupação; a_k , θ_k e *S* são independentes e $\{f_k\}_0^\infty$ é determinado empiricamente. A potência do k-ésimo multipercurso $S^{f_k}a_k$ é denotada na forma log normal conforme equação 3.7.

$$20\log_{10}(S^{f_k}a_k) = f_k(20\log_{10}S) + 20\log_{10}a_k \tag{3.7}$$

Os multipercursos são linearmente dependentes, todos possuem variável aleatória $20 log_{10}S$ e correlação tal qual na equação 3.8.

$$\lambda_{jk} = \frac{f_j f_k \sigma^2}{\sqrt{(f_k^2 \sigma^2 + \sigma_k^2) \left(f_j^2 \sigma^2 + \sigma_j^2\right)}}, j \neq k$$
(3.8)

A partir da análise e simulação, podem ser efetuadas algumas simplificações, mantendo a reprodução dos resultados praticamente exata. É possível considerar $f_k = 1$, para todo k, e $\sigma = 2 - 3$ dB.

3.5 PROPAGAÇÃO EM CONSTRUÇÕES COMO GUIA DE ONDA

Um guia de onda pode ser descrito como um tubo condutor oco composto por paredes compostas de materiais dielétricos com perdas. A recomendação ITU-R P.2040-1 [19] diz que estruturas como corredores e túneis podem ser consideradas como guias de onda, cujas constantes intrínsecas de perda dos materiais dielétricos são diferentes para as paredes, o teto e o piso. Esta aproximação mostra bons resultados com valores medidos em corredores, para frequências entre 200 MHz e 12 GHz, onde não há circulação de pedestres.

É possível verificar que a teoria de guia de onda é bastante condizente com a realidade para os casos em que não há obstáculos que causem sombreamento.

3.6 PERDA DE PENETRAÇÃO EM CONSTRUÇÕES

A perda de penetração em construções pode ser expressa pela diferença, em dB, entre o nível de sinal em espaço aberto, o mais próximo possível da construção onde incide, de preferência em linha de visada, e o nível de sinal dentro da construção. É importante que em ambos os casos a altura h seja a mesma, como se vê na Figura 3.4. Quanto menor for a distância entre as medições *outdoor* e *indoor*, melhor. Se esta distância for muito grande, deve-se considerar, também, a perda no espaço livre entre ambos [19].



Figura 3.4: Local de referência e medição para perda de penetração.

Segundo COST 231 [11], a perda de penetração pode ser dividida em quatro categorias principais:

- Wall loss Dependente do ângulo de incidência da OEM, é a perda de penetração através da parede. Sua determinação é difícil quando as medidas são realizadas dentro da construção, devido às múltiplas reflexões e mobílias próximas à parede. Uma única parede pode ter distintos valores de perda de penetração, dependendo da forma como o raio incide e se há ou não linha de visada.
- *Room loss* É a média de perdas determinada pelas medidas tomadas em todo o aposento de 1 a 2 metros acima do piso. Esta medida é útil em casos em que se possui a planta descrevendo a construção ou em salas muito grandes em que se pode dividir em menores para melhor verificação. Usualmente, é utilizado como *input* para modelos que consideram um ou vários raios através da construção.
- *Floor loss* É a média de perda de todos os cômodos de um mesmo piso.
- Building loss Similar à *floor loss*, mas considera a média de todos os pisos do edifício.

Em alguns casos, a perda de penetração diminui à medida que se passa para um andar mais elevado. Esta dependência é chamada de *floor height gain* e dada em dB/andar. Em sistemas microcelulares, onde a altura da antena transmissora está abaixo da altura das construções que a cercam, a perda de penetração em *Line of Sight* LOS mostra maior independência da altura do piso em distâncias maiores. Também válido para *NonLine of Sight* NLOS quando a maior parte da potência se propaga pelas ruas.

Diversas informações adicionais podem ser inseridas a fim de diminuir o erro das medições, conforme elencado em [19]. Todavia, a utilização de muitas informações de entrada geram maior processamento e tornam o modelo de predição muito específico, diminuindo bastante as regiões em que pode ser usado.

CAPÍTULO 4

4. REDES NEURAIS ARTIFICIAIS

Este capítulo dedica-se à descrição das principais características das redes neurais artificiais (RNAs), como a analogia com a rede neural humana, as diferentes topologias de rede, modos de aprendizado e principais algoritmos. Servirá de base para a verificação da eficiência das RNAs como ferramenta de predição de cobertura, quando comparadas a outros métodos de predição.

4.1 DEFINIÇÃO E PROPRIEDADES BÁSICAS

As RNAs funcionam de forma análoga a uma Rede Neural Humana. Sendo assim, suas variáveis são as conduções sinápticas e a tensão da membrana neural. As conduções sinápticas modelam, constantemente, a tensão na membrana neural através do tempo, enquanto o contrário é visto de forma discreta, no tempo, através de pulsos. No centro desta constante interação estão os neurônios. Segundo Simon Haykin [20] uma rede neural é um processador massivamente distribuído de forma paralela, composto de unidades de processamento simples com capacidade de armazenar conhecimento através de experiências, e poder utilizá-lo quando necessário. Como a rede neural humana, o conhecimento é adquirido no ambiente em que a rede está através do processo de aprendizado e a força entre as interconexões neurais (pesos das sinapses) que são utilizadas para guardar o conhecimento adquirido.

O procedimento utilizado no processo de aprendizado é chamado de algoritmo de aprendizado e é o responsável por modificar os pesos das sinapses a fim de obter o comportamento desejado para determinada rede. A habilidade de mudança e a forma como uma RNA é composta faz com que se tenha propriedades importantes e bastante eficientes, às quais seguem pontuadas abaixo.

Não-linearidade – um neurônio artificial pode ser linear ou não linear. Uma rede composta em sua plenitude por neurônios não-lineares é ela própria não-linear. Esta propriedade é bastante importante uma vez que diversos tipos de padrões encontrados são não lineares. A Figura 4.2 exemplifica tais padrões.



Figura 4.1: (a) par de padrões lineares. (b) par de padrões não-lineares.

- Mapeamento de Entrada-Saída o processo de aprendizado, supervisionado ou não, envolve a modificação dos pesos das sinapses baseada em alguns exemplos. Cada exemplo é formado por um sinal único de entrada e um valor desejado de saída. O treinamento e as alterações dos pesos sinápticos são efetuados uma série de vezes até a rede se estabilizar e não haver mais alterações significantes nos pesos.
- Adaptabilidade A rede neural treinada de acordo com determinado ambiente pode ter seus pesos alterados de acordo com um novo ambiente, através de nova rodada de treinamentos que pode ser realizada em tempo real se necessário.
- Resposta evidencial No contexto de classificação de padrões, além da capacidade de selecionar determinado padrão, o neurônio tem a capacidade de informar sobre a confiança na decisão que foi tomada. Desta forma, é possível rejeitar padrões ambíguos, caso ocorram, e melhorar o acertividade da classificação da rede.

4.2 CONFIGURAÇÃO BÁSICA DO NEURÔNIO

O neurônio é a unidade básica de processamento fundamental para o funcionamento de uma rede neural. A Figura 4.2 ilustra os seus componentes básicos.

- Grupo de sinapses e seus respectivos pesos. Determinado sinal de entrada x_j , localizado na sinapse *j* do neurônio *k*, é multiplicado pelo peso sináptico w_{kj} . Ao contrário do neurônio humano, o peso sináptico no neurônio artificial pode errar em casos em que os dados de entrada contenham valores positivos e negativos.
- Somador dos sinais de entrada, já multiplicados pelos respectivos pesos.
- Função de ativação para limitar a amplitude da saída do neurônio.



Figura 4.2: Modelo básico de neurônio.

O modelo possui, também, um parâmetro externo ao neurônio k chamado Bias b_k e pode ser considerado como novo peso sináptico, cujo valor de entrada é sempre +1. Tal parâmetro b_k funciona como limiar para função de ativação e pode ser aumentado ou diminuído, para conferir melhor adaptação por parte das redes neurais ao conhecimento a ela fornecido. Uma vez descritos os principais elementos de um neurônio e suas funções, sua forma matemática está descrita nas equações (4.1) e (4.2).

$$u_k = \sum_{j=1}^m w_{kj} x_j \tag{4.1}$$

$$y_k = \varphi(u_k + b_k) \tag{4.2}$$

onde $x_1, x_2, ..., x_m$ são os sinais de entrada, $w_{k1}, w_{k2}, ..., w_{km}$ os respectivos pesos das sinapses nervosas do neurônio k, u_k a saída do somador de todos os sinais já multiplicados pelo peso, b_k o valor do bias, $\varphi(.)$ a função de ativação e y_k o sinal de saída do neurônio. A utilização de b_k tem como finalidade aplicar uma transformação em u_k para servir de entrada à função de ativação seguindo a equação (4.3).

$$v_k = u_k + b_k \tag{4.3}$$

A função de ativação denotada por $\varphi(.)$, define a saída do neurônio em relação ao sinal de entrada v. É dividida entre função limiar (*threshold*) e função *Sigmoid*, que podem ser descritas respectivamente, pelas equações (4.4) e (4.5).

$$\varphi(v) = \begin{cases} 1, se \ v \ge 0\\ 0, se \ v < 0 \end{cases}$$
(4.4)

$$\varphi(v) = \frac{1}{1 + e^{-av}} \tag{4.5}$$

A função *sigmoid*, certamente é a função de ativação mais utilizada em redes neurais, pois consegue adequar-se melhor entre os comportamentos linear e não-linear, onde *a* representa o coeficiente de inclinação, conforme ilustrado na Figura 4.3b.



Figura 4.3: (a) Função Limiar (b) Função sigmoid.

Tanto a função linear quanto a função *sigmoid* assumem valores de saída entre 0 e 1. Diversas vezes, é necessário ter funções de ativação com outros intervalos de valores. Assim, a equação da função limiar (4.4) passa a ser descrita conforme a equação (4.6), comumente chamada de função *signum*.

$$\varphi(v) = \begin{cases} 1, se \ v > 0 \\ 0, se \ v = 0 \\ -1, se \ v < 0 \end{cases}$$
(4.6)

A função *sigmoid*, variando no intervalo entre -1 e 1, é definida pela função tangente hiperbólica, conforme equação (4.7). No MatLab[®], é representada pela função *tansig* (*Hyperbolic tangent sigmoid transfer function*).

$$\varphi(v) = tanh(v) \tag{4.7}$$

4.3 FEEDBACK

Feedback é um mecanismo que envolve a medição dos valores de saída de um sistema dinâmico e calcula sua diferença para os valores desejados. Esta diferença por sua vez é utilizada junto aos valores de entrada para gerar melhor aproximação dos valores de saída com os valores esperados. Neste sistema determinada saída pode influenciar, de alguma forma, uma nova entrada, alterando assim o valor de saída. Para isso, consideram-se o sinal de entrada $x_j(n)$, o sinal interno $x'_j(n)$ e o sinal de saída $y_k(n)$, como parte de um ciclo infinito dividido entre a parte progressiva (*forward*) e outra de retorno (*feedback*) de avaliação do resultado obtido no instante anterior, a fim de melhorar a precisão das próximas respostas. A Figura 4.4a mostra um ciclo único onde *w* representa o peso e z^{-1} um operador de atraso do último sinal de saída, que irá influenciar na próxima entrada.





Figura 4.4: (a) Gráfico do fluxo de sinal de primeira ordem de duração infinita. (b) Aproximação do sistema *feedforward*. Fonte: [20]

A Figura 4.4 b é representada, matematicamente, a partir da equação (4.8).

$$y_k(n) = w \sum_{l=0}^{\infty} w^{l+1} x_j(n-l)$$
(4.8)

Na equação 4.8, *l* representa a quantidade de unidades de tempo de atraso. A partir da equação e de sua ilustração gráfica, é possível verificar que o caráter dinâmico do sistema *feedforward* tem como responsável o peso *w*.

4.4 TOPOLOGIAS DE REDE NEURAIS

Há três topologias distintas de arquitetura de redes neurais. A forma mais simples de rede é conhecida como Rede de Camada Única e é formada pelas camadas de entrada e de neurônios (computação/processamento) em sistema de *feedforward*. A camada de entrada em redes neurais não é contabilizada no somatório de camadas da rede, uma vez que não há tratamento dos dados. Pode ser verificada na Figura 4.5a como exemplo, com 4 neurônios.



Figura 4.5: (a) Rede Camada Única. (b) Rede multicamadas com camada escondida. (c) Rede Recorrente sem ciclo de *fedforward* próprio e sem camada escondida. Fonte: [20]

Outra classe de arquitetura de redes neurais, que também utiliza o sistema *feedforward* é conhecida como multicamadas (MLP). Sua principal diferença da arquitetura mais simples é a presença de uma ou mais camadas escondidas. São assim chamadas, pois não são "vistas diretamente" pelos dados de entrada e saída. O gráfico da rede na Figura 4.5b ilustra uma rede multicamadas 10-4-2, assim referenciada, pois possui 10 dados de entrada, 4 neurônios em camada escondida e 2 neurônios na camada de saída. Uma rede onde todos os nós de determinada camada são conectados aos nós da próxima camada é chamada de totalmente conectada, enquanto uma rede parcialmente conectada é aquela em que falta uma destas conexões sinápticas.

Os neurônios escondidos funcionam como um detector de características. À medida que a informação passa através das camadas escondidas e a fase de treinamento evolui, os neurônios descobrem, de forma gradual, o comportamento e características dos dados utilizados.

Por fim, há a classe de Redes Recorrentes, forma mais complexa que pode ou não possuir camadas escondidas. Possui ao menos um ciclo de *feedback* que pode realimentar o próprio neurônio ou não. Neste caso, a realimentação é dirigida apenas para os demais neurônios, conforme Figura 4.5c.

4.5 PROCESSOS DE APRENDIZADO

Seguindo as redes neurais humanas, as redes neurais artificiais também possuem distintos modos de aprendizado de acordo com a interação com o meio, dados de entrada e valores esperados de saída. Os modos de aprendizado são subdivididos em categorias de acordo com os principais métodos utilizados, conforme mostra a Figura 4.6.



Figura 4.6: Tipos de Máquinas de Aprendizado.

 Aprendizado Supervisionado: O computador recebe algumas amostras de *inputs* e seus referentes *outputs* desejados, dados por um "treinador", então o computador tenta aprender uma regra geral que consiga mapear os *inputs* nos *outputs* recebidos. A Figura 4.7 exemplifica este tipo de aprendizado.



Figura 4.7: Diagrama de blocos de aprendizado supervisionado.

Rede não supervisionada: Não utiliza os parâmetros de saída durante o aprendizado. O algoritmo deve ser cuidadosamente planejado para tentar descobrir uma estrutura apenas com os *inputs* recebidos, não existe um "treinador" indicando a resposta desejada. Este tipo de tarefa é utilizado para descobrir padrões em uma determinada base de dados. É exemplificado na Figura 4.8.



Figura 4.8: Diagrama de blocos de aprendizado não supervisionado.

 Aprendizado reforçado: O programa de computador interage com um ambiente dinâmico, no qual determinada atividade está sendo realizada. Não há um "treinador" passando à rede os valores de saída esperados. Este tipo de aprendizado é aplicado, por exemplo, em jogos que aprendem o estilo do jogador, através de repetidas ações do mesmo, e se adaptam para aumentar a dificuldade da competição.

O uso de máquinas de aprendizado, entretanto, não é a solução de todos os problemas. Antes de utilizar este tipo de ferramenta, indiscriminadamente, é preciso avaliar alguns pontos, como por exemplo se é possível resolver com a programação convencional, qual o processamento necessário e verificar se a taxa de erro está dentro de um valor aceitável.

Como resposta a essas perguntas, este trabalho compara os resultados de uma máquina de aprendizagem com as soluções hoje utilizadas e descritas pelo ITU e COST 231 para modelos de predição de cobertura *outdoor-to-indoor*. Serão utilizadas Redes Neurais de aprendizado supervisionado.

Nos itens subsequentes, de forma mais detalhada, será visto o funcionamento das redes neurais e sua configuração neste trabalho.

4.6 ALGORITMO BACK-PROPAGATION

É considerado um algoritmo eficiente no treinamento de redes neurais do tipo MLP. O nome de *back-propagation* resume bem o modo de funcionamento do algoritmo, onde as derivadas parciais das funções custo, ligadas aos parâmetros de peso e *bias*, são determinadas pelo retorno dos sinais de erro computados pelos neurônios de saída propagados para as camadas anteriores. A Figura 4.9 representa o fluxo de sinal através do neurônio *j*, de acordo com o algoritmo.



Figura 4.9: Fluxo de Sinal através de um neurônio.

Este algoritmo calcula a máxima variação possível dos pesos das sinapses nervosas Δw_{ji} , que são proporcionais ao fator de sensibilidade representado pela derivada parcial $\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}$, representada pelo gradiente na equação (4.9). Descreve, então, a direção e o sentido de deslocamento para que seja possível obter a maior variação possível.

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_j(n)}$$
(4.9)

onde v_j representa o campo local induzido produzido a partir dos sinais de entrada e respectivos pesos do neurônio *j*, e_j representa o erro do sinal na saída e y_j , o sinal após a saída da função de ativação, tal que $y_j = \varphi(v_j(n))$. A partir do desenvolvimento desta equação, detalhado em [20], chega-se à equação (4.10), onde a correção de peso Δw_{ji} é o resultado da multiplicação entre a taxa de aprendizado η , o gradiente local $\delta_j(n)$, descrito na equação (4.11), e o sinal de entrada no neurônio $y_i(j)$.

$$\Delta w_{ji} = \eta \delta_j(n) y_i(j) \tag{4.10}$$

$$\delta_j(n) = e_j(n)\varphi'_j(v(n)) \tag{4.11}$$

Seu funcionamento é dividido em duas etapas de computação: a *forward pass* e a de *backpropagation*. Na etapa de *forward pass*, os pesos das sinapses permanecem inalterados e o sinais são computados neurônio por neurônio, enquanto a etapa de *backpropagation* se inicia na camada de saída, e o erro encontrado é passado de trás para frente, para que seja possível recalcular o gradiente local e permitir que alterações ineficientes nos pesos sejam corrigidas.

O algoritmo utilizado neste trabalho foi o Levenberg-Marquardt que é uma otimização do método de Gauss-Newton [20], que por sua vez é um aperfeiçoamento do método de Newton. Este último utiliza a derivada de segunda ordem através de expansão de série de Taylor para corrigir os pesos. Isso permite que além da informação do gradiente, seja usada informação sobre a curvatura da superfície do erro[21], pode ser descrito de acordo com a equação 4.12.

$$\Delta w = -H^{-1}g \tag{4.12}$$

onde $H = \nabla^2 \varepsilon(w)$ representa a hessiana da função custo $\varepsilon(w)$ e *g* seu vetor gradiente. Apesar deste método possuir rápida convergência, a avaliação do Hessiano pode ser extremamente complexa e não há como garantir que H(n)seja sempre positivo a cada interação. A fim de sobrepor tal limitação, por meio de aproximaxões, desenvolveu-se o método de Gauss-Newton dado pela equação (4.13).

$$\Delta w = [J^{T}(w)J(w)]^{-1}J^{T}(w)e(w)$$
(4.13)

O problema deste método consiste no fato de que a matriz $H = [J^T(w)J(w)]$, pode não ter inversa [22]. Levenberg-Marquardt propôs então a adição da parcela μI como solução. Este modelo é amplamente utilizado e funciona de acordo com a equação (4.12):

$$\Delta w = [J^{T}(w)J(w) + \mu I]^{-1}J^{T}(w)e(w)$$
(4.12)

onde μ é a constante de ganho, *I* é a matriz identidade, *J*(*w*) é a matriz Jacobiana [23] calculada a partir da matriz de erro *e*(*w*), onde *w* representa os pesos das sinapses nervosas. Quando μ possui valor baixo converge para Gauss-Newton enquanto um valor muito alto de μ indica uma solução com descida acentuada nos pesos das sinapses. Durante as interações iniciais o valor de μ começa alto (= 0,01) e a cada nova interação este valor é dividido por β (= 10), de forma a se aproximar melhor de Gauss-Newton. Todo o processo é repetido em rodadas de aprendizado, até que seja atingido desempenho aceitável para a rede [23]. Descrição detalhada sobre o algoritmo Levenberg-Marquardt pode ser verificada em [24].

Diz-se que o algoritmo convergiu quando é atingido um erro suficientemente baixo, em números, erros abaixo de 1% por período.

CAPÍTULO 5

5 CAMPANHA DE MEDIÇÕES E PROCESSAMENTO DOS DADOS

A descrição do ambiente de medições, os equipamentos utilizados e suas configurações, o modo como foi realizada a campanha de medições, as redes neurais utilizadas e seus processos de treinamento serão detalhados, neste capítulo, a fim de garantir que todos os possíveis fatores relevantes e premissas adotadas na obtenção dos resultados foram devidamente descritos.

5.1 DESCRIÇÃO DO AMBIENTES DE MEDIÇÕES

As medições foram realizadas nos cinco andares do bloco D da Escola de Engenharia da Universidade Federal Fluminense, no campus da Praia Vermelha. O receptor foi mantido em movimento retilíneo pelos corredores do edifício, representados pela linha vermelha na Figura 5.1, a uma velocidade média de 1,2 m/s e altura de 1,5 m a partir do assoalho de cada andar, simulando o perfil de usuário típico de redes móveis. O transmissor foi instalado no topo do Edifício do Instituto de Física, conforme se vê na Figura 5.1.



A linha preta representa a distância entre os edifícios, igual a 112 m, junto com a linha vermelha, que representa o percurso realizado pelo receptor no Bloco D, forma o ângulo de 156°. De posse destes valores, foi possível calcular a distância total entre Tx e Rx em todos os *n* pontos através da lei dos cossenos. Tal distância fica representada na Figura 5.1 pela linha verde, sendo calculada pela equação (5.1).

$$d(n)_{Total}^{2} = 112^{2} + d(n)^{2} - 224d(n)\cos 156^{\circ}$$
(5.1)

No topo do edifício da Física, a antena foi posicionada com um azimute de 80° e inclinação vertical (*tilt*) de 3°, de forma que todo o edifício da Engenharia fosse totalmente coberto pela zona de meia potência do lóbulo principal da antena e que a máxima potência fosse apontada para o 5° andar, conforme ilustrado na Figura 5.2. Para tal cálculo, foi considerada como altura total a soma entre a altitude do terreno e a altura do edifício. A antena transmissora foi instalada a uma altura de 43 metros em comparação com o nível do mar. O Bloco D da Engenharia foi construído a 23 metros do nível do mar e possui uma altura de 17 metros.



Figura 5.2: Cobertura antena transmissora no Bloco D da Engenharia.

Uma vez posicionada a antena transmissora, realizou-se varredura espectral por todo o *campus* a fim de verificar qualquer possível interferência nas medições a serem realizadas. a partir daí, foi escolhida a frequência de 768 MHz, uma vez constatada que a mesma estava livre de interferências. Com isso, evitou-se necessidade de solicitação de liberação junto à ANATEL.

5.2 SETUP DE MEDIÇÕES

Uma vez escolhidos o ambiente de medições e a frequência, esta seção descreve a etapa de configuração e montagem dos equipamentos para a realização do teste. Todos os equipamentos são de propriedade da UFF e estão disponíveis para utilização no Laboratório de Propagação do PPGSS em Engenharia Elétrica e de Telecomunicações.

5.2.1 ANTENAS DE TRANSMISSÃO E RECEPÇÃO

A antena transmissora foi instalada no topo do Instituto de Física, a uma altura total de 41 metros, considerando o somatório da altitude, altura do edifício e mastro. Foi utilizada a antena RFS modelo APX75-866512-CT0, que atende perfeitamente às necessidades do projeto, como pode ser confirmado pelas especificações da antena na Tabela 5.1.

Parâmetro	Medida	Valor
Faixa de Frequência	MHz	698-896
Ganho	dBi	14,1
Abertura Vertical	0	66
Abertura Horizontal	0	15
Tilt Elétrico	0	3
VSWR	-	1,4
Impedância	Ω	50
PotênciaMáxima de		
entrada	W	500

Tabela 5.1: Características básicas da Antena Transmissora.

É possível verificar, pelo diagrama de irradiação vertical da antena, que sua área de cobertura é bastante abrangente, o que requer cuidado especial com suas configurações em ambientes reais com diversas antenas, para que seja evitada a sobreposição de cobertura. Neste trabalho, foi priorizada a iluminação do edifício com o lóbulo principal, a fim de se conseguir linha de visada e ter a máxima potência chegando ao receptor. Por isso, foi utilizado tilt de 3°.



Figura 5.3: Diagrama de irradiação da antena transmissora.

/INFILSU 04/28	6/2016 (02:07:1	6 pm						Remote		l:
Col Status	M2 1.3	39 @76	68.0000	00 MHz						ŝ	Trace 611 VSWP
On	2.25										
Data Points	2.13										
551	2.00										
Output Power	1.88										
————	1.75										
	1.63										
	150						2				
	1.38										
	1.25										
Ref Plane 0.000 mm	1.13										
Smoothing %	Start F	req 75	8.000 N	ЛНz					Stop) Freq 778	.000 MHz
0	Mkr	Ref	Delta	Ref F	req 20 MHz	Ref A	mpl 2	Delta	Freq	Delta	Mag
Average Count	M2	ON	OFF7	68 00000		1.4	9				
	M3	ON	OFF 7	78.00000	00 MHz	1.2	6				
	M4	OFF	OFF								
Sweep Time	M5	OFF	OFF								
1.433 s	M6	OFF	OFF								

Figura 5.4: Curva da taxa de onda estacionária da antena transmissora.

A antena receptora utilizada foi uma omnidirecional, com 2 dBi de ganho para a faixa de 760 MHz, modelo CE-150727, da CELTA, mostrada na Fig. 5.5



Figura 5.5: Antena omnidirecional receptora.

5.2.2 GERADOR DE FUNÇÃO E ANALISADOR ESPECTRAL

O gerador de função utilizado foi o Anritsu MG3700A, que possui banda de operação entre 250 kHz e 3 GHz, resolução de 0,01 Hz e potência de transmissão entre -140 e +13

dBm. Este cumpre perfeitamente o objetivo de transmitir o sinal CW (*Continuous Wave*) faixa estreita, na frequência de 768 MHz.

Uma vez gerado o tom e enviado através da antena transmissora, o analisador Anritsu MS2038A, na função analisador espectral recebeu e armazenou o sinal medido ao longo dos corredores dos cinco andares. Tal equipamento pode operar na faixa de 9 kHz a 4 GHz, é portátil e possui memória interna suficiente para arquivamento dos dados.

5.2.3 PARÂMETROS E PROCEDIMENTOS BÁSICOS DE MEDIÇÃO

Uma vez que o ambiente de medições e os equipamentos utilizados já foram descritos, são mostrados na Figura 5.6 e na Tabela 5.2, respectivamente, o diagrama unifilar do sistema montado e as características básicas do sistema de medição.

O lado transmissor é composto de uma fonte de alimentação, do gerador de função que envia uma portadora de forma contínua no tempo para a antena diretiva fixa, que, por sua vez propaga o sinal para o meio ambiente. No lado receptor, a antena e o analisador espectral foram fixados sobre um carrinho a fim de garantir a mobilidade necessária. Após o término da bateria de medidas, os dados salvos foram descarregados para um computador, para processamento *offline*.



Figura 5.6: Diagrama unifilar da medição realizada.

Parâmetro	Unidade	Valor
Frequência Central	MHz	768
Potência de RF do Transmissor	dBm	6,5
Altura da Antena de Transmissão/Recepção	m	41 / 1,5
Ganho da Antena de Transmissão/Recepção	dBi	14,1 / 2
Perda Total nos cabos	dB	2
EiRP	dBm	18,6

Tabela 5.2: Parametrização utilizada no sistema de medição.

5.3 TAXA DE AMOSTRAGEM

A taxa de amostragem usada na coleta dos dados é um parâmetro muito importante para a medição, pois se forem colhidas poucas amostras por segundo pode haver perda de informação como a profundidade e a duração dos desvanecimentos, entretanto um grande número de amostras torna o programa muito pesado e de processamento lento. Assim, quando medidas faixa estreita são realizadas, para se obter o sinal de variação de pequena escala, observa-se que, amostras são adquiridas ao longo do tempo (proporcional à distância, para uma velocidade constante) durante a medição. Para que *fadings* profundos sejam detectados, é necessário que a distância entre duas amostras esteja abaixo de $0,5\lambda$. À esta regra chama-se condição de *fading* profundo. Nestes casos, Parsons [1] sugere que $d = 0,01\lambda$ deve ser usado. Observa-se que a condição de *fading* profundo satisfaz, também, ao Teorema de Nyquist e ao efeito Doppler, que aparece sobre a portadora, devido à mobilidade. Resumindo, da taxa de amostragem deve satisfazer a:

- Teorema de Nyquist: T_a≥ 2B , onde T_a é a taxa de amostragem e B é a faixa do sinal a ser amostrado. Isto garante recuperação do sinal sem *aliasing*;
- T_a ≥2(2f_m) = 4v/λ = v/(λ/4) = v/(0,25 λ), pois o sinal móvel sofre deslocamento de sua portadora (≡ Doppler) e sua faixa passa a ser de ± fm = 2f_m.

Assim, ficam satisfeitas a taxa de Nyquist e o deslocamento Doppler e verifica-se que se usada a taxa $T_a \ge v/(0,01\lambda) = 100 v/\lambda$, além de satisfazer às duas condições, também possibilitará detectar o desvanecimento profundo, segundo Parsons: $d \le 0,01 \lambda$. Na prática, tem-se observado em diversos estudos em ambiente *outdoor*, como o de Rappaport [14] e Vásquez [25], que $d = 0,05\lambda$ é suficiente para detectar tais *fadings*, equivalendo à taxa de 20 v/λ . Já em corredores de ambiente *indoor*, verificou-se que 40 v/λ é uma taxa mais adequada para a reprodução do sinal [26]. Com isto, diminui-se o processamento e também não se adquirem amostras com alta correlação.

Devido à possibilidade de se trabalhar com a taxa de amostragem de 40 v/ λ , esta foi a taxa empregada na captura dos dados. Assim, (T_a) é caracterizado conforme a equação (5.2).

$$T_a = 40\frac{v}{\lambda} = 40\frac{v}{\frac{c}{f}}$$
(5.2)

Considerando a velocidade média de pedestre v como 1,2m/s, chega-se ao valor abaixo para a taxa de amostragem necessária:

$$T_a = 40\frac{v}{\lambda} = 40\frac{1,2}{0,39} \cong 123 \,Amostras/s$$

5.4 ESCOLHA E CONFIGURAÇÃO DA REDE NEURAL

Trabalhos recentes [27] [28] [29] abordam a aplicação de RNAs em ambientes internos uma vez que é bastante complexa a criação de modelos que satisfaçam os mais variados cenários deste tipo de espaço. O mesmo ocorre para ambientes híbridos onde parte do caminho realizado pelo sinal da-se em ambiente externo e parte em ambiente interno, como ocorre neste trabalho.

Foi utilizada a topologia de rede de múltiplas camadas conhecida como *Feedfoward Multilayer Perceptron* (MLP) [23] [30] [31] [32]. Considerado o caráter não linear dos dados coletados, foram criadas duas RNAs com topologias distintas. A primeira, chamada de RNA 1 3-20-1, é constituída por 3 dados de entrada, 20 neurônios de camada escondida e 1 neurônio de camada de saída; a segunda, RNA 2 3-10-1, difere-se pelo número de neurônios na camada escondida, possuindo apenas 10. A variação na quantidade de neurônios é válida e ajuda principalmente em problemas em que as amostras não são linearmente separáveis pois ajuda a diminuir o erro da RNA. A Figura 5.7 ilustra a configuração das redes criadas.

Este tipo de rede (MLP) pode ser utilizado como uma função geral de aproximação. Pode aproximar qualquer função com um número finito de descontinuidades de forma aceitável, de acordo com a quantidade de neurônios que possui na camada escondida. O algoritmo de treinamento foi o *Backpropagation* com convergência Levenberg-Marquardt [23] [30] [31]. Há estudos específicos [33] [34] [35] focados na variação dos algoritmos de treinamento e convergência na busca de melhores resultados, tal variação não foi cogitada neste trabalho por se afastar do objetivo do mesmo. Foi selecionada a função de ativação *tansig* dentro das camadas escondidas e a função *purelin* na camada de saída [23] [30] [31], como se vê na Figura 5.8. Os neurônios de saída com função de ativação *tansig* são, frequentemente, utilizados para problemas de reconhecimento de padrões, enquanto que os neurônios de saída com função de ativação linear são utilizados para problemas de adaptação de funções. Todas as funções e algoritmos utilizados estão disponíveis na *toolbox nntool* específica do MatLab[®].





(b)

Figura 5.7: Redes neurais utilizadas (a) RNA 1 (b) RNA 2. (Fonte: Matlab [36])



Figura 5.8: Funções de ativação utilizadas. (Fonte: Matlab [37])

Os parâmetros de entrada utilizados foram a distância entre Tx e Rx, o número de paredes e/ou andares atravessados pelo sinal e o ângulo de incidência na superfícia externa do edifício. O ângulo de incidência apareceu, indiretamnete, na altura da receptora, uma vez que

foi sempre menor que 90° e diminuía proporcionalmente com a altura de cada andar. O parâmetro de saída utilizado foi o nível de sinal medido em dBm.

Demais parâmetros de entrada não variaram nesta medição. Logo, mesmo que fossem inseridos como entrada da RNA seriam constantes que não trariam qualquer tipo de alteração no resultado de saída e, por isso, descartados pela própria rede.

Povoada com as informações pertinentes, a rede encontra regras que tornem possíveis mapear os dados de entrada nos valores esperados, dados de saída, através do processo de aprendizado supervisionado. A utilização de redes neurais nesta configuração para modelos de predição é interessante pois considera todos os fenômenos de propagação [31].

A tabela 5.3 [19] elenca diversos outros parâmetros que também poderiam ser utilizados como dados de entrada para apurar a predição e diminuir o erro. Estudos apontam, também, a perda causada por obstrução do corpo humano como dado de entrada, com bastante peso no resultado [19]. Nas medições realizadas, não houve esta preocupação, pois a pessoa que empurrava o carrinho ficava atrás do mesmo, e as medições foram realizadas de longe para perto da antena transmissora, embora houvesse algum trânsito aleatório de alunos nos corredores sondados.

Parâmetro	Unidade ou Valores	Observações
Frequência	MHz	768 MHz
Ambiente da região	Aberto/suburbano/urbano/urbano denso	Necessário para estimar a importância do acoplamento através da energia dispersa de outros edifícios
Linha de visada para a construção	Sim/Não	Deve ser normalmente LoS para minimizar o erro de medição
Média	Espectral/espacial/outra	Campo de formato livre para permitir que o usuário descreva a forma de calcular a média (se houver) usada.

Tabela 5.3: Parâmetros de Medição.

	1 = terminal <i>indoor</i> dentro de uma sala/espaço com parede externa entre terminal <i>outdoor</i>		
Profundidade de penetração	2 = terminal <i>indoor</i> dentro de uma sala/espaço sem parede externa		
	3 = terminal <i>indoor</i> dentro de uma sala/espaço com outra parede externa		
Andar onde as medidas foram realizadas		Térreo = 0	
Área em que foram colhidas as amostras	metros quadrados		
Número de amostras		Deve ser tomado um número suficiente de amostras para fornecer confiança estatística nos resultados	
Dafarôncia	1 = mediana do sinal medido	Medição preferida sempre que	
Kelelellella	2 = perda no espaço livre predita	possível	
Distância de Tx à construção	Metros		
Ângulo de elevação do caminho	Graus		
Azimute mínimo em relação à superfície normal à construção	Graus		
Azimute máximo em relação à superfície normal à construção	Graus		

A RNA 1 utilizou 30% do total de amostras enquanto a RNA 2 utilizou apenas 20% do total da base de dados para treinamento, validação e teste. O total de amostras foi dividido em grupos subsequentes com 10 amostras cada e dentro de cada grupo cada amostra foi identificada com um número dentro do intervalo de 1 a 10. Ambas as redes foram treinadas com dois espaços amostrais, a fim de verificar a influência da escolha dos dados de treinamento no resultado final. O espaço amostral da RNA 1 foi composto pelas amostras 1, 2 e 3 enquanto o espaço amostral 2 foi composto pelas amostras 5, 6 e 7. Já para a RNA 2 o espaço amostral 1 contou com as amostras 1 e 2 e o espaço amostral 2 com as amostras 5 e 6. Uma vez treinadas, as redes foram povoadas com todos os valores de entrada da base de dados e, então, foram gerados os valores de saída baseados no que foi aprendido pela rede. Este resultado, então, será comparado às medidas coletadas e modelos de predição escolhidos.

A Figura 5.9 e a Figura 5.10 ilustram o desempenho das RNAs 1 e 2 durante a etapa de treinamento para o espaço amostral 1 de cada uma.



Figura 5.9: Erro quadrático médio (MSE) da RNA 1 durante processo de aprendizado.



Figura 5.10: MSE da RNA 2 durante processo de aprendizado.

A RNA 1 levou 414 períodos para convergir enquanto a RNA 2, apenas 164, o que demonstra que a RNA 2 é 2,5 vezes mais rápida que a RNA 1 no processamento computacional.

5.5 CÁLCULO DOS MODELOS DE PREDIÇÃO
Nesta seção, serão detalhados os parâmetros e valores utilizados nos modelos *indoor Multi-Wall* e *Partition-Based outdoor-to-indoor* para a frequência de 768 MHz. O erro destes modelos de predição está diretamente ligado à distância e quantidade de obstruções entre o transmissor e o receptor e ao valor de atenuação considerado para cada obstrução em determinada frequência.

• Partition-Based outdoor-to-indoor

Este modelo agrega à atenuação no espaço livre, o somatório de todas as perdas causadas pelas obstruções encontradas entre transmissor e receptor. Os valores de perda de penetração usados por Rappaport [14], entretanto, não puderam ser utilizados nos cálculos porque suas medições foram realizadas na frequência de 5,85 GHz. Segundo Aguirre [38], a perda média de penetração para frequências baixas, especificamente 912 MHz, é igual a 7,7 dB, enquanto COST 231 [11] diz que a perda em paredes de concreto é de 10 dB para paredes sem janela e de 7 dB para paredes com janela.

O conceito de perda por parede não deve ser pensado como sendo necessariamente a perda física que determinada parede impõe ao nível de sinal em uma parede homogênea. É, na verdade, um fator de correção, que gera maior aproximação do modelo com a realidade. Nele estão inseridas, também, as perdas causadas por objetos dentro da construção como armários, sofás, eletrodomésticos e outros móveis.

Dito isto, considerou-se então neste estudo a perda de 7 dB por parede sem distinção entre pisos e demais paredes. O cálculo foi realizado a partir deste valor, pela equação (3.5) e pela tabela 5.4.

• Multi-Wall

Apesar de ser um modelo puramente *indoor*, assim como o modelo *Partition-Based outdoor-to-indoor*, utiliza a atenuação no espaço livre em conjunto com valores empíricos de atenuação para diferentes tipos de obstrução. Desta forma, foi possível utilizá-lo para comparação neste trabalho. Considerando a estrutura do bloco D da Engenharia, a equação 3.3 e a frequência utilizada de 768 MHz, foi utilizado o valor de 5,4 dB para atenuação em paredes pesadas (L_{w2}) e 14,8 para atenuação entre pisos (L_f). O valor de L_c é resultado das medições empíricas das obstruções através de regressão linear, normalmente com valores bem próximos de zero e, neste trabalho, será considerado nulo. A constante empírica *b* será utilizada, conforme tabela 3.3, com valor de 0,46. Deste modo, "a equação 3.3 pode ser substituída pela equação 5.3".

$$L = L_{FS} + \sum_{i=1}^{I} 5,4k_{wi} + k_f \left[\frac{k_f + 2}{k_f + 1} - 0,46\right] 14,8$$
(5.3)

O valor de k_{wi} manteve-se constante durante toda campanha de medições com apenas uma parede, a parede externa, obstruindo o sinal que foi medido em corredores, entretanto, k_f variou de acordo com o andar, conforme tabela 5.4.

Tabela 5.4: Obstruções por andar.

Andar	Nº Paredes	Nº Pisos
2°	1	3
3°	1	2
4°	1	1
5°	1	0

CAPÍTULO 6

6 ANÁLISE DAS MEDIÇÕES

Uma vez adquiridos os níveis de sinal de cada andar, foram realizadas duas análises distintas: a primeira, de variabilidade em pequena escala do sinal rádio móvel e o ajuste das distribuições estatísticas Gaussiana, Rayleigh e Rice; a segunda análise consiste na comparação do nível de sinal das amostras coletadas com os valores estimados por modelos de predição e pelas redes neurais.

6.1 ANÁLISE ESTATÍSTICA DOS DADOS

A verificação da precisão dos modelos de predição pode ser realizada através do erro médio quadrático (EMQ) e do desvio padrão. Este tipo de comparação fornece uma perspectiva geral, embora nem sempre suficiente para as necessidades do sistema a ser projetado. Por esse motivo, há diversos estudos [39] [40] [41] que introduzem métricas adicionais a fim de prover maior confiabilidade à verificação de erro.

Tanto a análise de qual é a distribuição estatística que melhor se ajusta a cada andar quanto a análise de qual o método de predição que mais se aproximou dos valores medidos, será realizada a partir da Métrica D [41], explicada a seguir. Adicionalmente à métrica D, também será utilizada para comparação entre os métodos de predição a métrica *Total Hit Rate* (THR) [39].

• Métrica D

Esta métrica consiste no somatório dos módulos das diferenças entre os valores empíricos (f(x)) e os valores teóricos (g(x)). Genericamente, é a diferença entre as áreas das duas curvas, representadas por f(x) e g(x), conforme a equação (6.1).

$$D = \int |f(x) - g(x)| dx \tag{6.1}$$

A partir da equação (6.1), em ambas as análises, será obtida a norma L^1 através do somatório das diferenças $(D_1 + D_2 + \dots + D_n)$ das *n* amostras coletadas. A curva com menor valor de norma L^1 é, então, a que mais se aproxima dos valores discretos encontrados. A norma L^1 é representada pela equação (6.2).

$$L^{1} = \sum_{i=1}^{i=n} D(i)$$
(6.2)

• Total Hit Rate (THR)

Criada, especificamente, para melhorar a comparação de erro entre modelos de predição, esta métrica considera uma cobertura ponto-multiponto onde Tx é estática e Rx se move ao longo de determinado trajeto. Os valores medidos e calculados são comparados a determinado limiar, que pode ser a potência ou a perda de sinal.

A introdução de um limiar como métrica adicional é interessante e pode ser utilizado de várias formas de acordo com o interesse da pesquisa. Pode, por exemplo, ser o nível mínimo de sinal necessário que determinado serviço requer para funcionar de maneira satisfatória. Neste trabalho, foram utilizados os limiares de -80 dBm e -70 dBm. Valores abaixo do limiar de -80 dBm correspondem a desvanecimentos rápidos, aumentam muito o valor do erro médio e são apenas 3,57% do total de amostras medidas. O valor de -70 dBm foi utilizado para simular uma situação em que o sinal oscile próximo ao mínimo necessário para uma aplicação específica, e amostras abaixo do limiar correspondem a 25,5% do total. O limiar mais alto (-70 dBm) se aproxima mais dos valores encontrados neste trabalho e expõe melhor a diferença entre cada modo de predição conforme será verificado no item 6.3.

Todas as variáveis, valores medidos, preditos e limiares são considerados em módulo para os cálculos pelas fórmulas apresentadas. Se o módulo de uma amostra, em dBm, for menor que o limiar escolhido, então é dito que está dentro da área de cobertura e recebe valor 1. Caso contrário, diz-se que está fora da área de cobertura, conforme equação (6.3), e lhe é atribuído valor 0.

$$U(x) = \begin{cases} 1, \forall x \forall \leq L_T \\ 0, cc \end{cases}$$
(6.3)

e x corresponde às variáveis m_i ou p_i . Dentre as *i* amostras, o valor medido é descrito como m_i , o valor calculado como p_i e o limiar L_T . A partir dessa equação, chega-se à tabela verdade 6.1.

Tabela 6.1: Cenários possíveis de classificação das amostras empíricas e teóricas.

$U(p_i)$	$U(m_i)$	N_{pm}	Significado
0	0	N ₀₀	Número de amostras onde valores empíricos e teóricos são
0 0			classificados como fora da área de cobertura.
0	1	N ₀₁	Número de amostras onde valores teóricos são classificados como
0	1		dentro da área de cobertura.
1	0	N ₁₀	Número de amostras onde valores empíricos são classificados
1	0		como dentro da área de cobertura.
1	4	N ₁₁	Número de amostras onde valores empíricos e teóricos são
1	1		classificados como dentro da área de cobertura.

Apenas amostras em que valores medidos e valores calculados (previstos) concordem (estados 00 e 11) são considerados para a verificação da THR. Os estados utilizados são, então, considerados como dois eventos distintos onde 00 é o evento Q e 11 o evento S. Desta forma as equações (6.4) e (6.5) definem, respectivamente, a probabilidade de ocorrência do evento Q e do evento S.

$$P(Q) = \frac{\sum_{i} U(p_i)}{N_T}$$
(6.4)

$$P(S) = \frac{\sum_{i} U(m_i)}{N_T}$$
(6.5)

onde $N_T = N_{00} + N_{01} + N_{10} + N_{11}$ que corresponde ao total de amostras comparadas. Assim, chega-se à equação (6.6) de THR.

$$THR(L_T) = \frac{\sum_{i} U(m_i) U(p_i)}{N_T} + \frac{\sum_{i} \dot{U}(m_i) \dot{U}(p_i)}{N_T}$$
(6.6)

O resultado desta métrica é uma indicação da qualidade do modelo de predição, uma vez que indica a porcentagem de amostras teóricas e experimentais que se aproximam a partir de determinado limite teórico.

6.2 ANÁLISE DA VARIABILIDADE EM PEQUENA ESCALA DO SINAL

Antes de avaliar os resultados obtidos para cada perfil e compará-los, é necessário separar os desvanescimentos em pequena e grande escala. Para esta métrica, o importante é o desvanescimento em pequena escala.

Há diversos meios para executar esta separação, como a utilização da filtragem de média móvel e a separação de amostras em setores. Na separação em setores, de acordo com Lee [42], o total de amostras pode ser separado em setores de tamanhos que variam entre $20\lambda a 40\lambda$, o que proveria um espalhamento de 1 dB em torno da média, se a distribuição característica da variabilidade em pequena escala fosse a Rayleigh. O método de filtragem de média móvel separa as três principais componentes (a de pequena escala, a de larga escala e a perda no percurso) do sinal [43] [44]. O filtro de média móvel (FMM) utiliza uma janela de tamanho adequado para realizar tal separação. Após diversos testes chegou-se ao valor de 320 amostras para o tamanho de janela neste trabalho. Neste trabalho foi utilizado o método de separação por média móvel, desta forma foi possível desenhar de forma separada curvas apenas com o desvanescimento em pequena escala ou desvanescimento em larga escala.

A figura 6.1 ilustra o procedimento para a obtenção dos três efeitos do sinal separadamente. A partir da passagem do sinal pelo 1º filtro de média móvel (FMM1) obtémse o sombreamento somado à perda no percurso (S+P). A diferença entre o sinal na saída do FMM1 e o sinal de entrada (SO) resulta no sinal de desvanecimento em pequena escala (R). Tomando-se o sinal de saída do FMM1 e colocando como entrada do FMM2, obtém-se apenas a perda no percurso (P) na saída do FMM2 e, subtraindo-se esse sinal do sinal de entrada do FMM2 (S+P), obtém-se a variação em pequena escala do sinal (S). Enfim, passando o sinal original por dois filtros de média móvel, é possível se obter os três principais efeitos separados do sinal de variabilidade: desvanecimento em grande escala ou sombreamento, desvanecimento em pequena escala e perda no percurso (S, R e P).



Figura 6.1: Diagrama de blocos relativo às operações sobre o sinal medido.

Da Figura 6.2 à Figura 6.5, é possível ver o total de amostras do sinal, em dBm, distribuídas pela distância percorrida, assim como a média móvel por andar.



Figura 6.2: Sinal recebido em dBm no 2º andar do Bloco D de Engenharia da UFF.



Figura 6.3: Sinal recebido em dBm no 3º andar do Bloco D de Engenharia da UFF.



Figura 6.4: Sinal recebido em dBm no 4º andar do Bloco D de Engenharia da UFF.



Figura 6.5: Sinal recebido em dBm no 5º andar do Bloco D de Engenharia da UFF.

Nota-se que o 5° andar é o que possui melhores valores em nível de potência, de acordo com o que se esperava, ao apontar a máxima potência para este andar. A variação do sinal com a distância é pequena e num mesmo andar há zonas mais distantes da antena transmissora com média de sinal melhor. Este comportamento ocorre devido ao ambiente utilizado para medição, uma vez que o sinal passa do ambiente externo para o interior do edifício nos corredores e o sinal fica confinado e sem maiores obstruções. Apesar de possuir um desvanecimento em grande escala de pequena variação, o desvanecimento em pequena escala é bastante presente, também pelo fato do sinal estar confinado e sofrendro inúmeras reflexões. Assim, o sinal recebido a cada instante é resultado de somatórios construtivos ou

destrutivos dos multipercursos, o que explica os grandes vales com sinais até 30 dB menores que a média.

Utilizando a métrica D foi possível calcular qual distribuição estatística mais se aproximou dos valores mensurados. Em outras palavras, a distribuição com menor erro, portanto, de melhor ajuste. Todos os andares mostraram comportamento bastante semelhante e, consequentemente, a distribuição mais próxima foi quase sempre a mesma, na maioria das vezes a distribuição Rice a possuir o menor erro, conforme evidenciado pela tabela 6.2.

Erro calculado de Acordo com a Métrica D				
Distribuição/Andar	2 Andar	3 Andar	4 Andar	5 Andar
Gauss	0,798904	0,915918	0,740257	0,844082
Raileygh	2,595323	2,648098	2,484304	2,683113
Rice	0,772866	0,909652	0,725781	0,837166
K-Rice	26	21	36	24

Tabela 6.2: Métrica D aplicada a todos os andares, evidenciando os melhores ajustes.

Apesar da distribuição de Rice ser a que melhor se adaptou a todos os andares, observa-se que a de Gauss ficou com erros muito próximos, podendo-se dizer que o comportamento do sinal pode ser considerado gaussiano, uma vez que para fatores K de Rice mais elevados, esta distribuição se aproxima de uma distribuição gaussiana. A Tabela 6.2 também mostra os valores de K que melhor se ajustaram à distribuição para gerar o menor erro possível. Assim, o comportamento do sinal na frequência de 768 MHz, com cobertura *outdoor-indoor*, mostrou-se gaussiano. Como as medidas foram realizadas em ambiente *indoor*, onde o sinal foi obstruído por diversas paredes e pisos e a transmissão foi realizada a uma distância considerável em ambiente aberto, o sinal sofreu, também, a atenuação pela distância e sombreamento nos andares mais baixos A2 e A3 devido à vegetação presente no ambiente externo entre a transmissora e a receptora.

Quando o sinal penetra pelas paredes do edifício e se propaga pelo corredor, a variação de intensidade com a distância diminui, pois não há obstruções e o corredor funciona

como um guia de onda, mantendo o sinal confinado, de acordo com a recomendação ITU-R P.2040-1. O programa utilizado para calcular as distribuições, assim como o erro, a partir da métrica D, encontra-se no Apêndice 9.1. Os gráficos contendo os níveis de sinal, média e distribuições estatísticas de cada andar podem ser encontrados no apêndice 9.2.

6.3 COMPARAÇÃO ENTRE PREDIÇÕES DE COBERTURA

Uma vez conhecido o comportamento do canal rádio móvel no ambiente medido, foi realizada a comparação entre os níveis de sinal adquiridos com o modelo de propagação no espaço livre, modelo *Partition-Based Outdoor-to-indoor*, modelo *indoor Multi-Wall* Cost 231, conforme descrição dos modelos realizada no capítulo 3, e das redes neurais, RNA 1 e RNA 2, descritas no capítulo 5. Esta comparação se dá de duas formas: a primeira, pelo cálculo do erro médio através da métrica D e a segunda, através da utilização da THR, para que seja avaliada a qualidade de cada modelo.

Foram considerados, como dados de entrada para os modelos de predição, a distância e a quantidade de paredes/obstruções entre Tx e Rx assim como a frequência.

No caso das redes neurais, como a frequência não variou durante a fase de testes, esta medida tornou-se dispensável. Em contrapartida, foi possível utilizar a altura do receptor que representa o ângulo de incidência do raio na superfície externa conforme norma do ITU. A altura do receptor pode substituir o ângulo de incidência, uma vez que ambos variam apenas por andar e são diretamente proporcionais.

A Tabela 6.3 agrega os valores de entrada, por andar, à exceção da distância, que varia, também, por amostra. Já a Tabela 6.4 indica quais parâmetros foram utilizados para cada método de predição.

Tabela 6.3: Valores utilizados por andar.

Parâmetro de entrada	2º Andar	3º Andar	4º Andar	5º Andar
Número de Paredes	4	3	2	1
Altura do Receptor (m)	4,5	7,5	10,5	13,5
Frequência (MHz)	768	768	768	768

Tabela 6.4: Parâmetros de entrada por método de predição.

Métodos de Predição	Número de Paredes	Altura do Receptor (m)	Frequência (MHz)	Distância Tx/Rx (m)
Atenuação no espaço livre	4	*	*	*
PARTITION-BASED OUTDOOR-TO-INDOOR	✓	a k	×	×
Multi-Wall Cost 231	✓	*	×	✓
RNA 1	✓	✓	*	✓
RNA 2	✓	✓	×	✓

Os resultados obtidos, descritos na Tabela 6.5, demonstram que as redes neurais alcançaram menor erro de acordo com a métrica D e maior confiabilidade de acordo com a métrica THR, em ambos os limiares (-70 e -80 dBm).

Ao compararmos os modelos de predição com as redes neurais, é visível o ganho na diminuição do erro e aumento na eficiência. Outra vantagem significativa é não ser necessário o trabalho de realizar medições e calcular a atenuação em diversos tipos de obstruções.

Modelos de predição	Erro médio em dB (Métrica D)	THR(70)	THR(80)
Atenuação no Espaço Livre	7,677967636	0,744637	0,964283
Partition-Based Outdoor-to-Indoor	10,40324682	0,665022	0,791248
Multi-Wall Cost231	18,16415583	0,491229	0,53351
RNA 1 - Espaço amostral 1	5,655285711	0,813795	0,964283
RNA 2 - Espaço amostral 1	5,668215732	0,806837	0,964283
RNA 1 - Espaço amostral 2	5,557807938	0,808931	0,964283
RNA 2 - Espaço amostral 2	5,591117225	0,809817	0,964283

Tabela 6.5: Comparação de resultados entre os métodos de predição.

Considerando os resultados de THR, é possível observar menor eficiência para os modelos de predição *Multi-Wall* e *Partition-Based Outdoor-to-indoor* no limiar de 80 (nível de potência -80 dBm), o que indica que há maior quantidade de amostras em desencontro com os valores por estes preditos, equivalendo aos estados 10 e 01 da tabela 6.1. Já com o limiar de 70 (nível de potência -70 dBm), a eficiência destes dois modelos mais o modelo de atenuação no espaço livre cai bastante.

A partir do erro médio e da métrica THR obtidos, verifica-se que o modelo *Partition-Based Outdoor-to-indoor* de Rappaport, apesentou menor erro dentre os modelos de predição, entretanto, mostrou eficiência menor que o modelo de atenuação no espaço livre, demonstrando que as vezes em que a predição e os valores medidos encontraram-se no mesmo estado, cobertura ou fora de cobertura, de acordo com o limiar, foi menor para Rappaport, indício de que o modelo não trabalhou de forma satisfatória para o ambiente testado. Isto vai de encontro com a conclusão de Rappaport [14], que diz que este modelo funciona bem para distâncias menores que 50 m e para distâncias maiores, desde que haja poucas obstruções que causem espalhamento na região próxima. Caso contrário, os multipercursos passam a ser parte dominante do sinal recebido e o modelo perde sua significância.

A partir das figuras 6.6 a 6.9, fica bem visível que o modelo de atenuação no espaço livre, por não considerar as perdas por obstrução, mostra-se bastante otimista enquanto o modelo *Multi-Wall* foi o mais pessimista. Este último foi o pior e considera atenuação entre pisos com valor de 14,8 dB. Pode-se concluir que o sinal recebido é formado, principalmente, pelas componentes externas e possui pouca participação das componentes que passam entre os pisos, enquanto as RNAs 1 e 2 treinadas com o espaço amostral 1 mostraram-se bem próximas da média móvel por andar nas figuras 6.6 a 6.9. Pela figura 5.2, mostrou-se que todo o edifício está contido na região de meia potência do lóbulo principal, o que deu maior peso no sinal medido enquanto o sinal de máxima potência foi atenuado pelos pisos.



Figura 6.6: Nível de sinal recebido e métodos de predição aplicados no 2° andar.



Figura 6.7: Nível de sinal recebido e métodos de predição aplicados no 3° andar.



Figura 6.8: Nível de sinal recebido e métodos de predição aplicados no 4° andar



Figura 6.9: Nível de sinal recebido e métodos de predição aplicados no 5° andar

As redes neurais mostraram-se mais eficientes e foram as que possuíram maior quantidade de amostras em concordância com os valores medidos. Isto está de acordo com [30], que diz que a rede neural considera todos os fenômenos de propagação durante a predição. Adequou-se melhor, também, em função de sua propriedade de não-linearidade.

Conforme descrito, as redes neurais mostraram eficiência, tornando mais precisos os valores preditos em comparação com os modelos de predição, entretanto, quando realizamos a comparação entre as duas redes, há resultados bastante semelhantes. Apesar da leve vantagem

da RNA 1, esta possui processamento muito maior, conforme verificado no item 5.4. Assim, RNA 2 possui melhor relação erro médio por taxa de processamento e, com isso, torna-se mais adaptável para utilização prática no mercado de telecomunicações.

Os valores próximos de erro e THR para as RNAs treinadas com espaços distintos mostrou que a escolha de dados para treinamento foi bem realizada e não influenciou no resultado de saída das RNAs.

CAPÍTULO 7

7 CONCLUSÕES

A partir dos resultados detalhados sobre o comportamento do canal rádio móvel em faixa estreita e da comparação entre os distintos modelos de predição, RNAs e o sinal medido, foi possível chegar a um desfecho com pontos interessantes e oportunidades para pesquisas futuras.

O canal rádio móvel medido, nos quatro andares em que foram realizadas medições, apresentou comportamento bastante semelhante, convergiu à função densidade de probabilidade Rice com fator *K* sempre bem superior a 1, indicando que o sinal no receptor apresentou uma componente dominante forte e sua intensidade em cada ponto medido foi influenciada pela atenuação no espaço livre acrescida da perda de penetração causada pelas paredes e pisos e sombreamento nos andares inferiores devido às obstruções no caminho.

Após o sinal passar para o ambiente *indoor* e sofrer as perdas descritas, o mesmo apresentou variação menor em sua intensidade ao longo dos corredores na maioria das amostras, exceto por vales profundos causados pelo somatório de multipercursos em discordância de fase, o que indica um comportamento em ambiente confinado sem maiores obstáculos, tal qual o comportamento em guias de onda quadrados, conforme recomendação ITU-R P.2040-1 [19].

Conhecido o comportamento do sinal em ambiente *outdoor-to-indoor*, a etapa seguinte deste trabalho propôs-se a comparar distintos modelos de predição e RNAs treinadas a partir de uma porcentagem dos dados coletados. Verificou-se que a RNA 1 apresentou erro médio de 5,55 dB enquanto o melhor modelo de predição apresentou erro médio de 7,67 dB. Mostrou, também, a maior eficiência, com 81,38% dos valores preditos em concordância com os valores mensurados de acordo com THR, com limiar -70 dB. A adição de um limiar na

THR funciona como ferramenta importante para melhor configuração e funcionamento das redes móveis. Este pode, por exemplo, ser o limiar que determinado serviço necessita para seu bom funcionamento, todavia, apesar de a RNA1 atingir os melhores índices em comparação com os demais métodos, não é a que apresenta melhor custo benefício. A RNA 2, com erro médio apenas 0,04 dB maior e THR 0,6% pior, é considerada como o melhor método de predição. A diferença entre ambas mostrou-se muito pequena e torna-se desprezível se for levado em consideração também o processamento gasto durante a etapa de treinamento. A RNA 1 levou 414 épocas para convergir enquanto a RNA 2 apenas 164. Deste modo, a RNA 2, que utilizou menos dados para treinamento e menor quantidade de neurônios, mostrou-se mais eficiente para ser utilizada como ferramenta de predição no dia-a-dia em casos onde a quantidade de informação e diversidade de cenários seja maior.

O estudo de métodos de predição que possam se adequar a alterações de ambientes, frequência e demais parâmetros relevantes de forma dinâmica é cada vez mais importante para garantir que os serviços em redes móveis sejam prestados sem que haja qualquer tipo de interrupção e o usuário perceba uma falha.

Novos estudos utilizando campanha de medições mais abrangentes, com medidas *outdoor* e *indoor*, frequências diversas e potências de transmissão distintas, ajudarão no refinamento dos métodos de predição. Utilizar RNAs como coeficiente de ajuste para os modelos de predição, já existentes, segue como outra linha de trabalho com objetivos de diminuir seu erro médio e torná-los mais abrangentes [45]. Visto que todos os modelos utilizados possuem diversas limitações como locais a serem utilizados, distância entre Tx e Rx, frequências que abrangem, entre outros. Também como ideia para trabalhos futuros, pode ser verificado quando é relevante a utilização apenas de determinado modelo de predição, apenas de determinada RNA ou de um modelo de predição híbrido.

Outra oportunidade observada é a utilização de RNAs em conjunto com os *Meassurement Reports* que são enviados pelo usuário à rede móvel e utilizados para a alteração dos recursos reservados a este usuário. Ao utilizar o *Meassurement Reports* de forma isolada, a alocação de recursos e variação de ferramentas importantes como *Carrier Agregation*, modulação adaptativa, balanceamento de carga entre portadoras, eventos de reseleção e *handover*, dentre outros, é feita sempre de maneira reativa após leitura dos dados reportados. As RNAs poderiam ser povoadas com os dados colhidos pelos *Measurement Reports* e, em casos em que a probabilidade de acerto seja muito alta, poderiam tomar ações de forma preventiva. Como exemplo, evitar uma tentativa de *handover*, já prevendo que a diminuição no sinal será rápida e não suficiente para causar uma queda. Assim, vai diminuir a utilização de *offsets* e temporizadores para evitar *ping-pong* entre células e passaria a utilizar RNA.

CAPÍTULO 8

8 BIBLIOGRAFIA

[1] PARSONS, J.D. *The Mobile Radio Propagation Channel*. 2nd edition. New York: John Wiley & Sons, 2000.

[2]SILVA, G.V.F. *Telecomunicações sistemas de Radiovisibilidade*, Segunda Edição, Livros Técnicos e Científicos Editora, 1978.

[3] RAPPAPORT, T. S. Wireless communications: principles and practice. 2nd edition. USA: Prentice Hall, 2008.

[4] MOLISCH, A.F. Wireless Communications. 1st edition. New York: John Wiley & Sons, 2005, 622 pp.

[5] W. Chen, Y. Lin e J. Yang, "Hybrid prediction model for field strength with ray tracing and artificial neural networks," in Proc. of Communication Technology (ICCT) - IEEE 14th International Conference on , pp. 301 - 305, 2012.

[6] YACOUB, M.D. Foundations of Mobile Radio Engineering. 1st edition. CRC Press, Inc. Boca Raton, FL, USA ©1993.

[7] I. Vilovic, N. Brum e D. Milic, "Using Particle Swarm Optimization in Training Neural Network for Indoor Field Strenght Prediction," in Proc. of 51st International Symposium ELMAR, pp. 275 - 278, 28-30 September 2009.

[8] J.Walfisch and H.L. Bertoni, "A Theoretical model of UHF propagation in urban environments", IEEE Trans. Antennas Propagat., vol.36, 1988, pp.1788-1796.

[9] F.Ikegami, T.Takeuchi, and S.Yoshida, "Theoretical prediction of mean field strength for Urban Mobile Radio", IEEE Trans. Antennas Propagat., vol.39, no.3, pp 299-302, 1991.

[10] Doble John., "Introduction to Radio Propagation for Fixed and Mobile Communications", Artech House, Boston-London, 1996

[11] Cost Action 231, Digital mobile radio towards future generation systems – Final Report, Directorate-General Telecommunications, Information society, Information Market, and Exploitation of Research, 1999.

[12] C. Törnevik, J.-E. Berg, F Lotse, "900 MHz propagation measurements and path loss models for different indoor environments," Proc. IEEE VTC'93, New Jersey, USA, 1993

[13] FONTAN, F; HOVINEN, V. Building Entry Loss and Delay Spread Measurements on a Simulated HAP-to-Indoor Link at S-Band, EURASIP Journal on Wireless Communications and Ntworking, vol 2008, id. 427352, 2008.

[14] RAPPAPORT, T. S; DURING, G; XU, H. Measurements and Models for Radio Path Loss and Penetration Loss In and Around Homes and Trees at 5.85 GHz, IEEE Transactions on Communications, 1998. vol.46, no. 11, pp 1484-1496.

[15] J. Walfisch, H. L. Bertoni, "A theoretical model of UHF propagation in urban environments" IEEE Trans, on Antennas and Propagation, vol. 36, no. 12, pp. 1788-1796, Dec. 1988

[16] F. Ikegami, S. Yoshida, M. Umehira, "Propagation factors controlling mean field strength on urban streets," IEEE Trans, on Antennas and Propagation, vol. 32, no. 8, August 1984, pp. 822-829.

[17] M. Hata, "Empirical formula for propagation loss in land mobile radio services," IEEE Trans, on Vehicular Technology, vol. 29, pp. 317325, 1980.

[18] TURIN, G; CLAPP, F. A statistical Model of Urban Multipath Propagation, IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY, VOL. VT-21, NO. 1, FEBRUARY 1972

[19] Recommendation ITU-R P.2040-1, "Effects of building materials and structures on radiowave propagation above about 100 MHz", P SeriesRadiowave propagation, 2015.

[20] S. Haykin, Neural Networks and Learning Machines, Third Edition, McMaster University Hamilton, Ontario, Canada, Pearson Education, 2009

[21] Roweis, S., (2003), Levenberg Marquardt Optimization, Disponível em (www.cs.toronto.edu/~roweis/notes/lm.pdf).

[22] NETO, L.B. SIEIRA, A.C. Utilização de Redes Neurais Artificiais na determinação do coeficiente de influência para carregamentos triangulares e trapezoidais. ENGEVISTA, v. 9, n. 1, pp. 22-34, junho 2007. [23] A. Leire, R. Meenakshi and R. Karun, A Ray Launching-Neural Network Approach for Radio Wave Propagation Analysis in complex Indoor Environments, IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION, VOL. 62, NO. 5, pp. 2777-2786, MAY 2014.

[24] S. Haykin, Neural Networks: A Comprehensive Foundation. Upper Saddle River, NJ, USA: Prentice-Hall, 1999.

[25] VÁSQUEZ, E.J. Estudo de cobertura de sistemas móveis celulares em regiões urbanas, Dissertação de mestrado, CETUC/PUC-RJ, 2006

[26] MACHADO, D.G. Análise Estatística do Desvanecimento Rápido - Aplicação a um Sinal Rádio-Móvel de 1,75 GHz, em Ambiente LOS Indoor", UFF, 2010.

[27] J. Romo, I. Anitzine e F. Fontan, "Application of neural networks to field strengthPrediction for indoor environments," in Proc. of EuCAP, pp. 1 - 6, 2006.

[28] M. F. Iskander e Zhengqing Yun, Propagation prediction models for wireless communication systems, IEEE Transactions on Microwave Theory and Techniques, vol. 50, no. 3, pp. 662-673, mar. 2002.

[29] H. Zhou, F. Wang e C. Yang, "Application of artificial neural networks to the prediction offield strength in indoor environment for wireless LAN," in Proc. of Wireless Communications, Networking and Mobile Computing, pp. 1189 - 1192, 2005.

[30] M. Ayadi, A. Ben Zeinab and S. Tabbane, A Novel Approach for Indoor Wave Propagation Modeling, Ph.D. Thesis, Higher School of Communication of Tunisia Sup'Com, Ariana Tunisia, 2015.

[31] B. Monteiro, G. Cavalcante, H. Gomes, D. Rosário, Evaluation of Radio Propagation Parameters for Field Strength Prediction Using Neural Network, SBMO/IEEE MTT-S International Microwave & Optoelectronics Conference (IMOC 2007), pp.899-892, 2007.

[32] https://www.mathworks.com/help/nnet/index.html, Março 2017.

[33] C. Fang e S. Huairong, "Field strength prediction based on wavelet neural network,"Education Technology and Computer (ICETC) - in Proc. of 2nd International Conference on , pp. V2-255 - V2-258, 2010.

[34] I. Vilovic e N. Burum, "A comparison of MLP and RBF neural networks architectures forelectromagnetic field prediction in indoor environments," in Proc. of EUCAP pp. 1719 - 1723, 2011.

[35] D. Wu, G. Zhu e B. Ai, "Application of artificial neural networks for path loss prediction inrailway environments," Communications and Networking in China (CHINACOM), 5thInternational ICST Conference on , pp. 1 - 5, 2010.

[36] T. Benmus, R. Abboud and M. Shater, Neural Network Approach to Model the Propagation Path Loss for Great Tripoli Area at 900, 1800, and 2100 MHz Bands, STA'2015-PID3940-TCE, Monastir, Tunisia, 2015.

[37] https://www.mathworks.com/help/nnet/ug/multilayer-neural-network-architecture.html

[38] S. Aguirre, L.H. Loew, and L.Yeh, "Radio propagation into buildings at 912, 1920, and 5990 MHz using microcells," in Proc. 3rd IEEE ICUPC, Oct. 1994, pp. 129-134.

[39] A. S. Owadally, E. Montiel e S. R. Saunders, "A comparison of the accuracy of propagation models using hit rate analysis", Centre for Communications Systems Research, University of Surrey, Guildford GU2 7xH, England

[40] Han Wang, Wencai Du e Xing Chen, Evaluation of Radio over Sea Propagation Based ITU-R Recommendation P.1546-5, Ph.D. Thesis, College of Information Science & Technology, Hainan University, China, vol. 10, no. 14, pp. 231-237, 2015

[41] E. L. Lima, Espaços Métricos 2ª. Ed., RJ: IMPA, 1983.

[42] C. Y. LEE, Mobile Cellular Telecommunications Systems Communications Engineering, pág. 104-105, 1989

[43] PROAKIS, J. G. 2000. Digital Communications, 4th Ed., Mc Graw-Hill.

[44] ROLIM, T. H. P., Vono, A. O., NOVAES, C. D. & Guimarães, D. A., Um Método para Síntese e Análise dos Principais Efeitos de Propagação em Canais de Rádio Móvel, Revista de Telecomunicações – Inatel, v. 5, N. 1, 2002, 35-40.

[45] FERREIRA, P.F. "Improvement of Outdoor Signal Strength Prediction in UHF Band by Artificial Neural Network", in Proc. IEEE Transactions on Antennas and Propagation, vol. 64, pp. 5404-5410, 2016

CAPÍTULO 9

9 APÊNDICE

9.1 SCRIPT PARA CALCULAR E COMPARAR AS DISTRIBUIÇÕES

ESTATÍSTICAS AOS DADOS MEDIDOS

%%%SCRIPT PARA CALCULAR E COMPARAR AS DISTRIBUIÇÕES ESTATÍSTICAS AOS DADOS MEDIDOS%%%

```
clearall;
closeall;
clc;
i=[];
% Importa os dados obtidos nas medições (v/Lambda)
%r dBm=dlmread('teste2.txt','\n','A1..A5565');
%r=dlmread('teste3.txt','\n','A1..A5565');
Sinal=dlmread('A5.txt');
%%Sinal(find(Sinal(:,5)==1),1)
for i=1:7;
%% Calculo de PDF pelo histograma %
%num div=length(r);
num div=fix(sqrt(length(Sinal(Sinal(:,5)==i,4))));
% Dados do histograma
[n,xout] = hist(Sinal(Sinal(:,5)==i,4),num div);
[n dBm, xout dBm] = hist(Sinal(Sinal(:, 5) == i, 1), num div);
delta x=xout(2)-xout(1);
area hist=delta x.*n;
soma area hist=sum(area hist);
area pdf=area hist/soma area hist;
n pdf=area pdf/delta x;
% Desenha histograma
%
      figure(i);
%
      bar(xout, n pdf, 'w'), zoom on, grid on
%
      hold on;
% Distribuição de Gauss (Gaussiana)
nu=mean(Sinal(Sinal(:,5)==i,4));
sigma=std(Sinal(Sinal(:,5)==i,4));
p1=(1/(sqrt(2*pi)*sigma)).*exp((-1.*(Sinal(Sinal(:,5)==i,4)-
nu).^2)./(2*sigma^2));
pl qui=(1/(sqrt(2*pi)*sigma)).*exp((-1.*(xout-nu).^2)./(2*sigma^2));
% Desenha gráfico de Gauss
%figure(z)
8
      plot(Sinal(:,5)==i,4),p1,'--g','LineWidth',2);
9
      hold on;
% Distribuição de Raileygh
sigma ray=mean(Sinal(Sinal(:,5)==i,4))*sqrt(2/pi);
p2=(Sinal(Sinal(:,5)==i,4)./(sigma ray^2)).*(exp(-
((Sinal(Sinal(:,5)==i,4).^2)./(2*(sigma ray^2)))));
p2 qui=(xout./(sigma ray^2)).*(exp(-((xout.^2)/(2*sigma ray^2))));
% Desenha gráfico de Raileygh
      plot(Sinal(:,5)==i,4),p2,'-r','LineWidth',2);
2
```

```
hold on;
2
%% Distribuição de Rice para k fixo%
      kc=20;
2
      sigma rice=mean(Sinal(Sinal(:,5)==i,4))./(((sqrt(pi/2)*exp(-
2
kc/2)).*(((1+kc).*(besseli(0,kc/2)))+...
      (kc*besseli(1,kc/2))));
8
      r zero=sqrt(kc*2*(sigma rice^2));
0/2
      p3=(Sinal(Sinal(:,5)==i,4)./(sigma rice^2)).*(exp(-
8
((Sinal(Sinal(:,5)==i,4).^2+r zero^2)/(2*sigma rice^2)))).*...
      besseli(0, (r zero.*Sinal(Sinal(:,5)==i,4))/(sigma rice^2));
8
9
      % Desenha gráfico de Rice para k fixo
9
      %figure
      Valor k=int2str(kc);
%
      p3 qui=(xout./(sigma rice^2)).*(exp(-((xout.^2+r zero^2)/...
8
      (2*sigma rice^2)))).*besseli(0,(r zero.*xout)/(sigma rice^2));
8
8
      % Desenha gráfico de Rice para k fixo
8
      %figure
8
      Valor k=int2str(kc);
%Nset=int2str(z);
8
      figure(i);
8
      plot(Sinal(:,5)==i,4),p3,'-.b','LineWidth',2);
2
      h = legend('PDF Empirica', 'Gauss', 'Rayleigh', ['Rice
k=',Valor_k],2,'Location','NorthEast');
0
      set(h, 'Interpreter', 'none');
      xlabel('Sinal[normalizado]', 'FontSize', 11, 'FontWeight', 'bold')
2
8
      ylabel('Densidade ', 'FontSize', 11,'FontWeight', 'bold')
8
      titulo=('FDP Empírica vs. Distribuições Estatísticas');
8
      title(titulo, 'FontSize', 10, 'FontWeight', 'bold');
8
      hold off;
%saveas(figure(i),['Histograma A5 S',i],'fig');
%saveas(figure(z),['Setorizado', Nset],'png');
2
%% Distribuição de Rice variando K %
p3_v=[];
p3_qui_v=[];
Error_p3_v=[];
Total Error p3 v(1,:)=100000000000000000000000000000000000;
k ideal(i)=0;
for kc v=0:50;
l=kc v+2;
sigma rice=mean(Sinal(Sinal(:,5)==i,4))./(((sqrt(pi/2)*exp(-
kc v/2)).*(((1+kc v).*(besseli(0,kc v/2)))+...
(kc v*besseli(1,kc v/2))));
r zero v=sqrt(kc v*2*(sigma rice^2));
p3 v(l,:)=(Sinal(Sinal(:,5)==i,4)./(sigma rice^2)).*(exp(-
((Sinal(Sinal(:,5)==i,4).^2+r zero v^2)/(2*sigma rice^2)))).*...
besseli(0,(r zero v.*Sinal(Sinal(:,5)==i,4))/(sigma rice^2));
% Desenha gráfico de Rice para k fixo
%figure
Valor k v=int2str(kc v);
p3 qui v(l,:)=(xout./(sigma rice^2)).*(exp(-((xout.^2+r zero v^2)/...
(2*sigma rice^2)))).*besseli(0,(r zero v.*xout)/(sigma rice^2));
% Desenha gráfico de Rice para k fixo
%figure
Valor k v=int2str(kc v);
for j=1:num div;
Error p3 v(l,j)=abs(p3 qui v(l,j)-n pdf(1,j));
end
Total Error p3 v(l,:)=sum(Error p3 v(l,:));
if Total_Error_p3_v(l,:)<Total_Error_p3 v(l-1,:);</pre>
k ideal(i)=kc v;
```

end end

```
sigma_rice=mean(Sinal(Sinal(:,5)==i,4))./(((sqrt(pi/2)*exp(-
k_ideal(i)/2)).*(((1+k_ideal(i)).*(besseli(0,k_ideal(i)/2)))+...
(k_ideal(i)*besseli(1,k_ideal(i)/2))));
r_zero_ideal=sqrt(k_ideal(i)*2*(sigma_rice^2));
p3 qui ideal=(xout./(sigma rice^2)).*(exp(-((xout.^2+r zero ideal^2)/...
(2*sigma rice^2)))).*besseli(0,(r zero ideal.*xout)/(sigma rice^2));
Valor k ideal=int2str(k ideal(i));
%% Desenha as figuras
figure(i+7)
set(gcf, 'Color', 'white')
subplot(2,1,1)
      plot(xout, n pdf, '-go', 'LineWidth', 2);
2
bar(xout, n pdf, 'w'), zoom on, grid on
holdon;
plot(xout,p1 qui,'-b','LineWidth',2);
holdon;
plot(xout,p2 qui,'-r','LineWidth',2);
holdon;
plot(xout,p3 qui ideal,'-m','LineWidth',2);
h = legend('PDF Empirica', 'Gauss', 'Rayleigh', ['Rice
k=',Valor k ideal],2,'Location','NorthWest');
xlabel('Sinal [ordenado e normalizado]', 'FontSize', 14, 'FontWeight',
'bold')
ylabel('Densidade de Probabilidade', 'FontSize', 14, 'FontWeight', 'bold')
titulo=['FDP Empírica vs. Distribuições Estatísticas - A5S',num2str(i)];
title(titulo, 'FontSize', 14, 'FontWeight', 'bold');
gridon;
holdoff;
%set(gca, 'Color', 'black');
subplot(2,1,2)
plot(xout dBm,n pdf,'-go','LineWidth',2);
xlabel('Sinal (dBm)', 'FontSize', 14,'FontWeight', 'bold')
ylabel('Densidade de Probabilidade', 'FontSize', 14, 'FontWeight', 'bold')
titulo dBm=['FDP Empírica vs. Sinal (dBm) - A5S',num2str(i)];
title(titulo dBm, 'FontSize', 14, 'FontWeight', 'bold');
gridon;
%set(gca, 'Color', 'black');
name=['LineChart A5 S',num2str(i)];
saveas(figure(i+7),name,'fig');
figure(i+14)
set(gcf, 'Color', 'white')
subplot(2,1,1)
plot(Sinal(:,5)==i,3),'-r','LineWidth',2);
holdon;
plot(Sinal(:,5)==i,1),'-g','LineWidth',2);
xlabel('Amostras (#)', 'FontSize', 14,'FontWeight', 'bold')
ylabel('Sinal (dBm) ', 'FontSize', 14,'FontWeight', 'bold')
titulo=['Sinal (dBm) & Média do setor (dB) - A5S',num2str(i)];
title(titulo, 'FontSize', 14, 'FontWeight', 'bold');
gridon;
holdoff;
%set(gca, 'Color', 'black');
subplot(2,1,2)
```

```
plot(Sinal(Sinal(:,5)==i,2),'-g','LineWidth',2);
xlabel('Amostras (#)', 'FontSize', 14,'FontWeight', 'bold')
ylabel('Sinal Normalizado (dB) ', 'FontSize', 14,'FontWeight', 'bold')
titulo=['Sinal Normalizado (dB) - A5S',num2str(i)];
title(titulo, 'FontSize', 10,'FontWeight', 'bold');
gridon;
%set(gca,'Color','black');
name=['LineChart_A5_S',num2str(i)];
saveas(figure(i+14),name,'fig');
%%Erro distribuições estatísticas
gtde_amostras=fix(length(Sinal(Sinal(:,5)==i,4))/num_div);
```

```
for j=1:num_div;
Error_p1(j)=abs(p1_qui(j)-n_pdf(j));
Error_p2(j)=abs(p2_qui(j)-n_pdf(j));
Error_p3_ideal(j)=abs(p3_qui_ideal(j)-n_pdf(j));
end:
```

```
Total_Error_p1(i)=sum(Error_p1);
Total_Error_p2(i)=sum(Error_p2);
Total_Error_p3_ideal(i)=sum(Error_p3_ideal);
```

end

9.2 SCRIPT REDES NEURAIS ARTIFICIAIS

• RNA composta por 10 neurônios e treinada a partir de 20% dos dados.

```
function net = create fit net(inputs,targets)
%CREATE FIT NET Creates and trains a fitting neural network.
00
00
  NET = CREATE FIT NET(INPUTS, TARGETS) takes these arguments:
8
     INPUTS - RxQ matrix of Q R-element input samples
8
     TARGETS - SxQ matrix of Q S-element associated target
samples
  arranged as columns, and returns these results:
8
%
    NET - The trained neural network
00
00
  For example, to solve the Simple Fit dataset problem with
this function:
2
%
     load simplefit dataset
9
     net = create fit net(simplefitInputs,simplefitTargets);
     simplefitOutputs = sim(net,simplefitInputs);
9
00
90
  To reproduce the results you obtained in NFTOOL:
8
     net = create fit net(Tinput 20 10', Ttarget 20 10');
9
% Create Network
numHiddenNeurons = 10; % Adjust as desired
net = newfit(inputs,targets,numHiddenNeurons);
net.divideParam.trainRatio = 70/100; % Adjust as desired
net.divideParam.valRatio = 15/100; % Adjust as desired
```

```
net.divideParam.testRatio = 15/100; % Adjust as desired
% Train and Apply Network
[net,tr] = train(net,inputs,targets);
outputs = sim(net,inputs);
% Plot
plotperf(tr)
plotfit(net,inputs,targets)
plotregression(targets,outputs)
```

• RNA composta por 20 neurônios e treinada a partir de 30% dos dados.

```
function net = create fit net(inputs,targets)
%CREATE FIT NET Creates and trains a fitting neural network.
8
8
  NET = CREATE FIT NET(INPUTS, TARGETS) takes these arguments:
00
     INPUTS - RxQ matrix of Q R-element input samples
9
     TARGETS - SxQ matrix of Q S-element associated target
samples
  arranged as columns, and returns these results:
8
     NET - The trained neural network
8
8
% For example, to solve the Simple Fit dataset problem with
this function:
2
9
     load simplefit dataset
00
     net = create fit net(simplefitInputs,simplefitTargets);
8
     simplefitOutputs = sim(net, simplefitInputs);
8
9
  To reproduce the results you obtained in NFTOOL:
8
     net = create fit net(Tinput 30 20', Ttarget 30 20');
00
% Create Network
numHiddenNeurons = 20; % Adjust as desired
net = newfit(inputs,targets,numHiddenNeurons);
net.divideParam.trainRatio = 70/100; % Adjust as desired
net.divideParam.valRatio = 15/100; % Adjust as desired
net.divideParam.testRatio = 15/100; % Adjust as desired
% Train and Apply Network
[net,tr] = train(net,inputs,targets);
outputs = sim(net, inputs);
% Plot
plotperf(tr)
plotfit(net, inputs, targets)
plotregression(targets, outputs)
```

9.3 GRÁFICOS DAS FDPs POR ANDAR













