



**TESE DE DOUTORADO EM ENGENHARIA
ELÉTRICA**

**ANÁLISE DE PROPAGAÇÃO EM VEGETAÇÃO
UTILIZANDO BAYES E UT**

Alexandre José Figueiredo Loureiro

Brasília, julho de 2018

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA

UNIVERSIDADE DE BRASÍLIA

Faculdade de Tecnologia

TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA

ANÁLISE DE PROPAGAÇÃO EM VEGETAÇÃO UTILIZANDO BAYES E UT

Alexandre José Figueiredo Loureiro

Tese de Doutorado submetida ao Departamento de Engenharia Elétrica da Faculdade de Tecnologia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do grau de Doutor

Banca Examinadora

Prof. Leonardo Rodrigues Araújo Xavier de Menezes, PhD. (ENE-UnB) (Orientador)

Prof. Ugo Dias, PhD. (ENE-UnB)
(Examinador Interno)

Prof. Leonardo Aguayo, PhD. (UnB-Gama)
(Examinador Externo do Programa)

Prof. Robson Domingos, PhD.
(Examinador Externo da UnB)

Prof. Marcelino Monteiro, PhD. (UnB-Gama)
(Examinador Externo do Programa)

Prof. Paulo Portela, PhD. (ENE-UnB)
(Examinador Interno)

FICHA CATALOGRÁFICA

LOUREIRO, ALEXANDRE JOSE FIGUEIREDO

Análise de propagação em vegetação utilizando Bayes e UT. [Distrito Federal] 2018.
xiv, 70p., 210 x 297 mm (ENE/FT/UnB, Doutor, Telecomunicações, 2018).

Tese de Doutorado - Universidade de Brasília.

Faculdade de Tecnologia.

Departamento de Engenharia Elétrica.

- | | |
|------------------------------|------------------------------------|
| 1. Propagação em vegetação | 2. Medições em Ondas Centimétricas |
| 3. Transformada da Incerteza | 4. Teorema de Bayes |
| I. ENE/FT/UnB | II. Título (série) |

REFERÊNCIA BIBLIOGRÁFICA

LOUREIRO, A. J. F. (2018). Análise de propagação em vegetação utilizando Bayes e UT. Tese de Doutorado em Telecomunicações, Publicação PPGENE.TD - 131/2018, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 70p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Alexandre José Figueiredo Loureiro.

TÍTULO DA TESE DE DOUTORADO: Análise de propagação em vegetação utilizando Bayes e UT.

GRAU / ANO: Doutor / 2018

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor.

Alexandre José Figueiredo Loureiro
Departamento de Engenharia Elétrica - Universidade de Brasília
Brasília - DF - Brasil.

Dedicatória

Este trabalho é dedicado a Jesus Cristo, nosso Senhor, a minha esposa Renata de Souza Couto Loureiro, e a meus filhos Rafaela e Miguel, pelo incondicional amor e apoio.

Alexandre José Figueiredo Loureiro

Agradecimentos

Agradeço a Deus.

Agradeço a minha esposa Renata, a meus filhos Rafaela e Miguel pela paciência e apoio.

Agradeço ao meu pai e a minha mãe.

Agradeço ao professor, orientador deste trabalho e amigo Leonardo Rodrigues Araújo Xavier de Menezes sempre muito motivado e perspicaz ao longo deste estudo.

Agradeço aos colegas da Ektrum, da UFSJ (Universidade Federal de São João del-Rei), do INDT (Instituto de Desenvolvimento Tecnológico) e da Universidade de Aalborg na Dinamarca pelo suporte e motivação neste estudo.

Alexandre José Figueiredo Loureiro

A vegetação é considerada um ambiente complexo para análise de espalhamento e atenuação dentro do fenômeno de propagação de ondas rádio. Esta tese apresenta um preditor bayesiano de atenuação de propagação de ondas de rádio em vegetação baseado na sua correlação com pixels de vegetação de uma imagem e utilizando as vantagens computacionais da transformada da incerteza (UT). O processamento de imagens de satélite pode refinar o planejamento de sistemas de rádio usando a vegetação como preditor de atenuação. Neste trabalho a predição é baseada na correlação de mais de 56% entre valores de pixel RGB e valores de atenuação na vegetação obtida de três grupos de medições de potência em testes de campo em ondas centimétricas em duas regiões distintas do Brasil: Belo Horizonte, na região sudeste com medições em 18 GHz, e Manaus em 24 GHz na região norte. Esta predição aplicada nos dois grupos de medições em Manaus apresentou correlações de 0,59 e 0,56 respectivamente enquanto que em Belo Horizonte apresentou correlação de 0,57. As análises estatísticas mostraram que mais de 30% da variância da atenuação nestes três grupos de medições podem ser explicadas pelos valores de pixel RGB. Utilizando este modelo linear correlacionado entre pixels RGB de vegetação e valores geolocalizados de atenuação, este trabalho combina a Transformada da Incerteza (UT) e a inferência de Bayes para refinar a distribuição de atenuação em vegetação. Como a necessária multiplicação das distribuições prior e amostral de Bayes não está facilmente disponível na UT, este trabalho apresenta um método que calcula novos pontos sigma comuns, mas com diferentes pesos para as distribuições prior e amostral da UT, desta forma permitindo a multiplicação de Bayes.

ABSTRACT

The vegetation is considered a complex environment for analysis of scattering and attenuation in radio propagation phenomena. This thesis presents a bayesian predictor for radio propagation attenuation through vegetation based on the its correlation with vegetation pixels from an image and utilizing the computational advantages of the unscented transform (UT). The satellite image processing can improve planning of radio systems with a vegetation attenuation predictor. In this research, the prediction is based on the correlation of more than 56% between RGB pixel values and vegetation attenuation taken from three groups of power measurements at centimeter waves at two distinct regions of Brazil: Belo Horizonte, in the southeast region measured at 18 GHz, and Manaus at 24 GHz in the north region. This prediction applied at two groups of power measurements at Manaus showed correlation 0.62 and 0.56 respectively, while at Belo Horizonte showed correlation of 0.57. The statistical analysis showed that more than 30% of the attenuation variance at these three measurements groups was due to the RGB pixel values. Using this linear correlated model between vegetation pixel RGB values and geolocated attenuation values, this work combined the unscented transform (UT) and bayesian inference to refine the vegetation attenuation distribution. Since the necessary multiplication of bayes prior and sampling distributions is not easily available in the UT, this research presents a method that calculates new common sigma points and different new weights for the prior and sampling UT distributions, thus allowing the Bayes multiplication.

SUMÁRIO

1 INTRODUÇÃO	1
1.1 CONTEXUALIZAÇÃO	1
1.2 OBJETIVOS DO TRABALHO	4
1.3 ESTRUTURA DO TRABALHO	4
2 TRANSFORMADA DA INCERTEZA	6
2.1 DEFINIÇÃO DA UT	6
2.2 FORMULAÇÃO ANALÍTICA DA UT	6
2.3 DETERMINAÇÃO DOS PONTOS SIGMA	8
2.4 TABELAS DE PONTOS SIGMA E PESOS DA UT	10
2.5 CRITÉRIO DE PARADA DA UT	11
2.6 APLICAÇÕES DA UT EM TELECOMUNICAÇÕES	12
2.7 CONSIDERAÇÕES FINAIS DA UT	14
3 COMPATIBILIZAÇÃO ENTRE O TEOREMA DE BAYES E TRANSFORMADA DA INCERTEZA.....	15
3.1 FUNDAMENTOS DO TEOREMA DE BAYES	15
3.2 INFERÊNCIA BAYESIANA	16
3.3 APLICAÇÃO DA TRANSFORMADA DA INCERTEZA AO TEOREMA DE BAYES	21
3.4 CONSIDERAÇÕES FINAIS DA UT APLICADA A BAYES	29
4 PROPAGAÇÃO DE ONDAS ELETROMAGNÉTICAS EM VEGETAÇÃO	31
4.1 ATENUAÇÃO E ESPALHAMENTO DO SINAL DEVIDO A VEGETAÇÃO	31
4.2 MODELOS DE ATENUAÇÃO DEVIDO A VEGETAÇÃO	31
4.2.1 MODELOS EMPÍRICOS	32
4.2.2 MODELOS SEMI-EMPÍRICOS.....	33
4.2.3 MODELOS ANALÍTICOS	34
4.3 CONSIDERAÇÕES FINAIS DOS MODELOS DE ATENUAÇÃO EM VEGETAÇÃO	37
5 CAMPANHA DE MEDIÇÕES DE CAMPO.....	39
5.1 CENÁRIO DE MEDIÇÕES	39
5.2 CONFIGURAÇÃO DE MEDIÇÕES E PROCEDIMENTOS	43
5.3 RESULTADOS DAS MEDIÇÕES.....	44
5.4 ANÁLISE DAS MEDIÇÕES.....	46
5.5 CONSIDERAÇÕES FINAIS DA CAMPANHA DE MEDIÇÕES	47
6 PROCESSAMENTO DA IMAGEM DE VEGETAÇÃO.....	48
6.1 FILTRAGEM DE PIXELS DA VEGETAÇÃO	48
6.2 ANÁLISE DE PIXELS.....	50
7 METODOLOGIA DE CARACTERIZAÇÃO DA ATENUAÇÃO NA VEGETAÇÃO	55
7.1 MAPEAMENTO DE PIXELS RGB EM ATENUAÇÃO NA VEGETAÇÃO	55
7.2 TRANSFORMADA DA INCERTEZA APLICADA AO TEOREMA DE BAYES	58
7.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO	63
CONCLUSÃO	64
8.1 CONTRIBUIÇÕES.....	66
8.2 TRABALHOS FUTUROS	66
REFERÊNCIAS BIBLIOGRÁFICAS	68

LISTA DE FIGURAS

2.1	Princípio da transformada da Incerteza (Unscented Transform)	7
2.2	Princípio da UT aplicada a uma distribuição Gaussiana	7
2.3	Função densidade de probabilidade contínua e a aproximação discreta	9
2.4	Simulação com MC (esquerda)e a simulação com UT (direita).....	13
2.5	Simulações usando MC e UT	14
3.1	Formas da distribuição <i>priori</i> para diferentes graus de certeza	18
3.2	Influência das distribuições <i>Priori</i> e Amostral na <i>Posteriori</i>	19
3.3	Método de multiplicação de distribuições binomiais aplicado na inferência bayesiana	22
3.4	Método de multiplicação de UTs aplicado na inferência bayesiana.....	24
3.5	Distribuição UT da Prior e Sampling binomial com 2 pontos sigma e respectivos pesos (linhas tracejadas)	25
3.6	Distribuição UT da <i>posteriori</i> binomial com 2 pontos sigma e respectivos pesos (linhas tracejadas)	25
3.7	Distribuição UT da Prior Binomial com 4 pontos sigma e respectivos pesos	27
3.8	Distribuição UT da Sampling Binomial com 4 pontos sigma e respectivos pesos.....	27
3.9	Distribuição UT da <i>posteriori</i> binomial com 4 pontos sigma e respectivos pesos.....	28
3.10	Distribuição UT de atenuação da vegetação: <i>posteriori</i> , <i>priori</i> e <i>sampling</i> (grupo 2) ..	29
4.1	Modelos empíricos de atenuação em vegetação	33
4.2	Geometria do cenário no modelo DG	34
4.3	Camadas heterogêneas dos modelos GTD/UTD	35
4.4	Quatro camadas homogêneas dos modelos GTD/UTD	35
4.5	Espalhamento de um meio randômico homogêneo de espalhadores.....	36
4.6	Comparação entre medições e modelo RET em 11GHz	36
4.7	Volume de vegetação dividido em células cúbicas no modelo dRET	37
4.8	Comparativo de vários dos modelos em 2,5GHz em uma plantação de palmeiras	37
5.1	Vista aérea 3D do cenário de vegetação: TX e posições medidas dos grupos 1 e 2.....	40
5.2	Vista aérea do cenário de vegetação, posições medidas e geometria considerada [8] no grupo 1.	40
5.3	Vista aérea do cenário de vegetação e posições medidas [6] no grupo 2	41
5.4.	Vista aérea 3D do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição	42
5.5	Vista 2D do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição	42
5.6	Referências de azimute, AoA das componentes de multipercurso devido a vegetação e reflexões em prédios no ponto 3	45
5.7	Resultado de medições no ponto 3: valores de potência direcional absoluta recebida para cada elevação (mapa de calor e diagrama polar)	46
5.8	Resultado de medições no ponto 3: valor médio de potência das três elevações medidas (+10, +20, +30)	46
6.1	Imagem de satélite após filtro para selecionar os pixels de vegetação (grupo 1 de Manaus)	49
6.2	Imagem de satélite após filtro para selecionar os pixels de vegetação (grupo 2 de Manaus) e retângulo verde mostrando pixels contíguos ao ponto de medição 12.....	50
6.3	Área azul mostra exemplo de região da imagem de satélite considerada na análise de pixels de vegetação (grupo 1 de Manaus)	51
6.4	Área azul mostra exemplo de região da imagem de satélite considerada na análise de pixels de vegetação (grupo 2 de Manaus)	51

6.5	Vista do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição	52
7.1	Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para o grupo 1 de Manaus.....	56
7.2	Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para o grupo 2 de Manaus	57
7.3	Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para Belo Horizonte	57
7.4	Distribuição UT dos valores RGB de pixels e de atenuação da vegetação (grupo 1 de Manaus)	59
7.5	Distribuição UT dos valores RGB de pixels e de atenuação da vegetação (grupo 2 de Manaus)	60
7.6	Método de mapeamento de pixels RGB em atenuação e aplicação da UT na inferência bayesiana para obter a atenuação na vegetação	61
7.7	Distribuição UT de atenuação da vegetação em Manaus: <i>posteriori</i> , <i>priori</i> e <i>sampling</i>	62

LISTA DE TABELAS

2.1	Pontos sigma e pesos para distribuição gaussiana $N \sim (0, \sigma^2)$	9
2.2	Pontos sigma e pesos para distribuição gaussiana $N \sim (\mu = 0, \sigma = 1)$	10
2.3	Pontos sigma e pesos para distribuição uniforme $U(-1, +1)$	11
2.4	Exemplo de critério de parada de acordo com a precisão dos momentos	12
2.5	Parâmetros utilizados na simulação	12
2.6	Resultados obtidos da simulação	14
3.1	Quantidade de equações e momentos de acordo com a quantidade de pontos sigma	23
3.2	Resumo comparativo de resultados com e sem a UT	30
5.1	Sumário dos parâmetros de cada ponto medido no cenário e respectivos valores medidos	47
7.1	Sumário dos parâmetros e valores da soma de RGB de cada ponto do grupo 1 de Manaus	55

LISTA DE SIGLAS

4K	Resolução de imagem com 3840 pixels na horizontal e 2160 na vertical
8K	Resolução de imagem com 7680 pixels na horizontal e 4320 na vertical
ACLR	<i>Adjacent channel leakage ratio</i>
ACS	<i>Adjacent channel selectivity</i>
AoA	<i>Angle of Arrival</i>
API	<i>Application programming interface</i>
APS	<i>Antennas & Propagation Society Symposium</i>
BH	Belo Horizonte
CW	<i>Continuous Wave</i>
CEFET	Centro Federal de Educação Tecnológica de Minas Gerais
DG	<i>Dual Gradient (DG) Model</i>
dRET	<i>Discrete Radiative Energy Transfer</i>
EIRP	<i>Effective Isotropic Radiated Power</i>
EuCAP	<i>European Conference on Antennas and Propagation</i>
FITU-R	<i>Fitted ITU-R</i>
FSPL	<i>Free Space Path Loss</i>
FUCAPI	Fundação Centro de Análise, Pesquisa e Inovação Tecnológica
GTD/UTD	<i>Geometrical and Uniform Theories of Diffraction</i>
HPBW	<i>Half-Power Beam Width</i>
HSI	<i>Hue Saturation Intensity</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IoT	Internet das Coisas
ITU-R	<i>International Telecommunication Union – Radio Communication Sector</i>
IV	Infravermelho
JMOE	<i>Journal of Microwaves, Optoelectronics and Electromagnetic Applications</i>
L^*a^*b	<i>Lightness and a and b color-opponent dimensions</i>
LOS	<i>Line of Sight</i>
LPWA	<i>Low power wide area</i>
LTE	<i>Long Term Evolution</i>
MED	<i>Modified Exponential Decay Model</i>
MC	Monte Carlo
NLOS	<i>Non Line of Sight</i>
NZG	<i>Non Zero Gradient (NZG) Model</i>
PL	<i>Path Loss</i>
RET	<i>Radiative Energy Transfer</i>
RGB	<i>Red green and blue</i>
TVRO	<i>Television receive-only</i>
URSI	<i>International Union of Radio Science</i>
UT	<i>Unscented Transform</i>

LISTA DE SÍMBOLOS E DE OPERAÇÕES MATEMÁTICAS

$\text{Bin}(n;p)$	distribuição binomial com n experimentos e probabilidade p .
C_{xx}	co-variância da variável aleatória X .
$E\{X\}$	esperança da variável aleatória X .
$E\{X^k\}$	momento de ordem k da variável aleatória X .
E_c	é o valor esperado da distribuição contínua.
E_d	é o valor esperado da distribuição discreta.
p_i	i -ésimo peso da Transformada da Incerteza (UT).
$P(y \theta)$	probabilidade de ocorrer uma variável y dado que ocorreu a variável θ
S_i	i -ésimo ponto-sigma da Transformada da Incerteza (UT).
\hat{u}	representa o conjunto de variáveis aleatórias.
μ_x	média da variável aleatória X .
$U(a,b)$	distribuição uniforme no intervalo entre a e b .
$U_i R_i$	união do conjunto finito de variáveis R_i .
$w(\hat{u})$	função densidade de probabilidade contínua de \hat{u} .
w_i	i -ésimo peso da UT que é uma função densidade de probabilidade discreta.
y, θ	variáveis aleatórias.

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A capacidade de tráfego das redes móveis sem fio está tendo que ser ampliada devido aos novos serviços que utilizam mídias intensivas em consumo de banda e ao aumento na quantidade de pessoas e coisas conectadas as redes de banda larga móvel. A quantidade de dispositivos conectados per capita está aumentando motivado principalmente pelo advento das redes de Internet das Coisas (IoT). Um exemplo de um novo serviço intensivo no consumo de banda larga móvel são os diversos serviços gratuitos atualmente disponíveis que permitem que qualquer usuário de um *smartphone* seja capaz de transmitir vídeo móvel em tempo real. A tendência é que a resolução e a qualidade da imagem destes vídeos evoluam para padrões de alta definição conhecidos como 4K e 8K. Serviços como realidade virtual, realidade aumentada, hologramas e visão computacional inclusive utilizando inteligência artificial serão cada vez mais utilizados em redes de banda larga móvel. Novos dispositivos *wearables* como pulseiras ou óculos de realidade estendida que combinam realidade virtual e realidade aumentada irão aumentar o tráfego de dados.

Para atender esta demanda crescente novas faixas de frequência em espectros mais altos estão sendo avaliadas [1][2][3][4][5][48]. O padrão IEEE 802.11ad conhecido como WiGig já está utilizando espectro em 60 GHz enquanto o padrão 3GPP de quinta geração está instalando as primeiras redes em espectros entre 6 GHz e 90 GHz. Estas faixas de espectro mais altas são denominadas de faixas de ondas centimétricas (3 GHz à 30 GHz) e de ondas milimétricas (30 GHz à 300 GHz). Tanto a academia quanto a indústria buscam caracterizar a propagação nestas novas faixas de frequência com o intuito de desenvolver novos equipamentos e planejar novas redes. Apesar da alta frequência estes novos espectros estão sendo utilizados em ambiente *outdoor* utilizando em geral células com raios de cobertura em torno de 200 metros [2][4][5] conhecidas como *small cells*.

A vegetação é uma componente intrínseca da maioria dos cenários *outdoor*, e seu efeito na propagação de ondas de rádio vem sendo estudado por décadas. Existem modelos de propagação em ambiente vegetação que são empíricos, que são baseados em medições de campo, modelos analíticos, que são baseados em análises da geometria do ambiente de propagação, e os modelos semi-empíricos que combinam medições de campo com análise da

geometria. A vegetação é considerada um ambiente complexo para análise de espalhamento e atenuação da propagação das ondas de rádio. A atenuação devido à vegetação aumenta em frequências de ondas centimétricas (3-30 GHz) e ondas milimétricas (30-300 GHz) quando comparado com frequências abaixo de 6 GHz, que são faixas de espectro mais utilizadas em redes celulares atualmente. A razão deste efeito é que em comprimentos de onda menores os obstáculos fixos como troncos de árvores e folhas causam maior bloqueio da zona de Fresnel [6]. Outro efeito característico de vegetação é o aumento do espalhamento devido à folhagem com o aumento da frequência [7].

Este trabalho apresenta uma metodologia para análise e caracterização da propagação de ondas de rádio frequência através de um ambiente de vegetação. Esta metodologia é baseada na correlação entre a atenuação e os valores de RGB (*red green blue*) de pixels de vegetação extraídos de uma imagem tirada via satélite. Esta correlação pode ser entendida como uma proposta desta tese de tornar os valores do pixel uma aproximação da densidade de vegetação do ambiente de propagação o que permitiria estimar a atenuação da vegetação. O acesso gratuito a imagens via satélite atualmente em ferramentas como *Google Earth* motivam a aplicação deste tipo de metodologia para predição e aumentam o potencial de adoção pelo mercado. Esta metodologia utiliza como ferramenta estatística a Transformada da Incerteza (UT) aplicada ao teorema de Bayes. A UT é aplicada com o objetivo de reduzir o esforço computacional nos cálculos do preditor como pode ser observado em diversas referências bibliográficas que mostram os ganhos da UT na redução da quantidade de amostras e conseqüentemente no tempo de processamento de análises estatísticas [10][11][14][15][16]. A inferência bayesiana permite que novas amostras representadas na distribuição *sampling* combinadas com o conhecimento prévio do modelo representadas na distribuição *priori* sejam usadas para calcular uma distribuição posteriori de atenuação das ondas de rádio ao se propagarem na vegetação. Este trabalho apresenta uma metodologia inovadora de compatibilização entre a UT e o teorema de Bayes que foi desenvolvida para permitir a multiplicação das distribuições *priori* (*prior*) e de amostragem (*sampling*) necessárias no cálculo da distribuição *posteriori*. Esta metodologia foi desenvolvida pois não foi encontrada abordagem similar no estado da arte. As distribuições UT são distribuições discretas. A multiplicação de distribuições discretas terá resultado não nulo apenas se estas distribuições tiverem valores probabilísticos diferentes de zero para os mesmos valores das variáveis aleatórias. Se uma distribuição tiver probabilidade não nula para determinados valores de uma variável aleatória, mas para estes mesmos valores da variável aleatória outra distribuição tiver probabilidades nulas isto implica que a multiplicação destas distribuições terá resultado nulo. Este é o caso da multiplicação de distribuições UT e a solução inovadora

desenvolvida utiliza as propriedades estatísticas da UT para obrigar que as distribuições tenham valor probabilístico nos mesmos pontos das variáveis aleatórias, ou seja nos mesmos pontos sigma da UT.

A automação do processo de captura de imagens via satélite na metodologia desenvolvida foi obtida pela utilização de uma API (*application programming interface*) do Google para captura das imagens. O desenho analítico da geometria de propagação de acordo com os ângulos de abertura das antenas de transmissão e de recepção foi realizado utilizando esta mesma API. Esta geometria é alterada de acordo com o azimute da antena de recepção que está colocada sob um pedestal rotativo. O processo de filtragem dos pixels de vegetação da imagem utilizou algoritmos abertos disponíveis na comunidade científica e estes permitiram uma análise mais precisa da correlação entre pixels e atenuação. A extração de pixels de vegetação é bastante utilizada para diferentes aplicações por exemplo a identificação de obstáculos por câmera para navegação de veículos autônomos ou a caracterização de mudanças e da qualidade do ecossistema de vegetação baseado em imagens via satélite. Os pixels são classificados como pixels de vegetação de acordo com seu valor numérico de RGB ou de HSI (*hue saturation intensity*). O algoritmo utilizado foi o L^*a^*b para segmentação em um espaço amostral de cores que consiste de uma camada de luminosidade ' L^* ', uma camada de cromaticidade ' a^* ' indicando a cor em uma escala de verde-vermelho e uma camada de cromaticidade ' b^* ' indicando a cor em uma escala de azul-amarelo.

Estas metodologias de correlação entre pixels e vegetação foram aplicadas sobre medições de atenuação coletadas em testes de campo em cenários de vegetação na faixa do espectro de ondas centimétricas, mais especificamente em 18 GHz e em 24 GHz. Estas medições de campo foram coletadas de trabalhos científicos anteriores a este que realizaram um conjunto de medições em uma região densamente arborizada de Manaus (AM) em 24 GHz e em uma região de vegetação típica de Belo Horizonte (MG) em 18 GHz. Foram obtidas atenuações em várias configurações de azimute, inclinação e distância entre o transmissor e o receptor [6][8][9]. Enquanto a região de Manaus apresenta uma vegetação típica da floresta amazônica inserida em região suburbana da cidade de Manaus na região de Belo Horizonte tem-se uma vegetação suburbana típica da região centro-oeste do Brasil onde predominam os biomas da Mata Atlântica e do Cerrado.

A necessidade de predição de propagação em diferentes cenários é uma atividade corriqueira que é executada diariamente por operadoras de redes celulares em diversos ambientes ao redor do mundo. A execução de testes de campo é uma atividade dispendiosa, que consome tempo e que está sujeita a muitos retrabalhos. Outra área que necessita de predições são simuladores de propagação em ambiente controlado utilizados no

desenvolvimento de novas tecnologias principalmente pelos fabricantes de infraestrutura de redes de telecomunicações celulares. As técnicas desenvolvidas nesta tese podem ser úteis tanto em ferramentas de predição de propagação como em simuladores de redes móveis sem fio nas faixas de ondas centimétricas em presença de vegetação. Este preditor pode vir a ser testado em ondas milimétricas ou em espectros mais baixos como os utilizados pela maioria das operadoras celulares. Estas outras faixas de frequência não foram testadas nesta tese devido a não disponibilidade de medições de campo, mas espera-se que com o mesmo procedimento apresentado nesta tese o resultado seja similar.

1.2 OBJETIVOS DO TRABALHO

Pretende-se neste trabalho abordar o tema de propagação de ondas centimétricas (3 a 30 GHz) em vegetação e apresentar propostas de metodologias de análise estatística nesta faixa de frequência.

As contribuições desta tese são:

- apresentar metodologia de utilização da transformada da incerteza (UT) aplicada ao teorema de Bayes;
 - apresentar procedimento de UT aplicada a multiplicação de distribuições;
- apresentar metodologia que caracteriza a atenuação de ondas centimétricas em ambiente de vegetação utilizando modelo empírico baseado em valores de RGB de pixels de uma imagem e a UT aplicada ao teorema de Bayes.

1.3 ESTRUTURA DO TRABALHO

Este estudo é organizado em oito capítulos incluindo o presente Capítulo da introdução e o Capítulo da conclusão.

No Capítulo 2 é apresentada a revisão bibliográfica da Transformada da Incerteza (UT), explicando em detalhes a sua interpretação estatística e matemática além de apresentar o procedimento para determinação dos pesos e pontos sigma de uma distribuição UT.

No Capítulo 3 é apresentado a definição do Teorema de Bayes e a metodologia desenvolvida para aplicação da Transformada da Incerteza em conjunto com o Teorema de Bayes utilizando procedimento inovador desenvolvido nesta tese que permite a multiplicação de distribuições UT. Neste capítulo é apresentada a validação da metodologia de multiplicação de distribuições UT que pode ser aplicada no teorema de Bayes ou em qualquer outra situação que envolva multiplicação de distribuições.

No Capítulo 4 é apresentada a revisão bibliográfica de modelos de propagação de ondas eletromagnéticas em um cenário outdoor de vegetação, caracterizando os efeitos de atenuação e espalhamento do sinal nos 3 diferentes tipos de modelos de propagação em vegetação: empírico, semi-empírico e analítico. São comentados os estudos prévios que realizaram coletas de medidas de atenuação em ambiente de vegetação.

No Capítulo 5 são apresentados de forma resumida os detalhes da campanha de coleta de medidas de campo de potência sinal recebido em ambiente de vegetação em Manaus e em Belo Horizonte. Estas medições foram realizadas pelos estudos anteriores que serviram de base de dados para testar as metodologias de análise apresentadas nesta tese.

No Capítulo 6 é apresentada a metodologia usada para filtrar os pixels de vegetação de imagens de satélite em dois diferentes cenários, em Manaus e Belo Horizonte, calculando os valores de RGB dos pixels pertinentes à propagação do sinal. Nesta metodologia estão inclusas a API do Google Earth e os algoritmos de filtragem dos pixels de vegetação.

No Capítulo 7 é finalmente apresentada a metodologia do preditor de atenuação que aplica a Transformada da Incerteza em conjunto com o Teorema de Bayes para inferir a atenuação em vegetação em função de valores RGB dos pixels de vegetação da imagem do ambiente de Manaus.

No Capítulo 8 é apresentada a conclusão dos resultados obtidos e das metodologias inovadoras desenvolvidas neste trabalho para predição de atenuação baseada em pixels de vegetação. Neste também são apresentadas as contribuições em artigos e revistas além dos trabalhos futuros envolvendo atividades que não conseguiram ser realizados nesta tese.

2 TRANSFORMADA DA INCERTEZA

2.1 DEFINIÇÃO DA UT

A Transformada da Incerteza (*Unscented Transform*) foi desenvolvida por Julier e Uhlman em 1997 [10], mas versões similares da técnica pode ser encontrada em outras referências [11][12]. O procedimento da UT pode ser entendido por diferentes formas. A UT pode ser vista como uma expansão de Taylor de um mapeamento não linear, ou como uma aproximação discreta de uma função densidade de probabilidade (PDF), ou também pode ser estudada como uma integração de quadraturas Gaussianas [13]. A UT é um método para calcular as estatísticas de uma variável aleatória que sofre uma transformação não linear. O princípio básico da UT é a aproximação de um mapeamento não linear por um conjunto de pontos selecionados, chamados de pontos sigma, e seus pesos associados. As estatísticas de média, variância e demais momentos do mapeamento estarão disponíveis a partir de uma ponderação destes pontos sigma [11]. O mapeamento não linear é basicamente o cálculo dos parâmetros da UT definidos como pontos sigma e pesos dos pontos sigma.

Os pontos sigma da UT são pontos selecionados de uma distribuição discreta que quando ponderados pelos seus respectivos pesos apresentam os mesmos momentos da distribuição contínua que sofreu o mapeamento não linear da UT.

Os pesos da UT correspondem a ponderação aplicada aos pontos sigma da distribuição discreta que foram obtidos pelo mapeamento não linear da UT aplicados a distribuição contínua de forma que ambas as distribuições, contínua e discreta, apresentem os mesmos momentos.

2.2 FORMULAÇÃO ANALÍTICA DA UT

O problema em questão pode ser colocado da seguinte maneira [10][14]: seja um vetor n -dimensional de variáveis aleatórias x , com média μ_x e uma co-variância C_{xx} , que sofre uma transformação não linear que relaciona x a y , dada por $y = g(x)$. Deseja-se então uma aproximação para a média μ_y e a covariância C_{yy} para a variável aleatória y resultante da transformação não-linear.

Este problema pode ser resolvido pelo método de Monte Carlo. A UT, entretanto, apresenta uma nova abordagem de resolução, que requer um menor esforço computacional

quando comparado ao método de Monte Carlo [15][16][17]. Em [17] mostra-se que simulações de 192 eventos utilizando UT conseguem ter resultados estatísticos similares a simulações de Monte Carlo que precisam de 10.000 ou até mesmo 100.000 eventos. A UT é baseada na intuição de que “com um número fixo de parâmetros é mais fácil aproximar uma distribuição gaussiana do que aproximar uma função/distribuição arbitrária não-linear” [10]. O objetivo da UT é encontrar uma parametrização que capture a informação da média, da covariância e dos demais momentos ao passo que permita a propagação direta desta informação através de um conjunto de equações não-lineares. Esta parametrização na UT é composta dos pontos sigma e seus respectivos pesos. A UT encontra estes parâmetros a partir da geração de uma distribuição discreta que possua os mesmos momentos de primeira e segunda ordem (ou mais) da variável aleatória, onde cada ponto desta aproximação discreta pode ser transformado diretamente. A média, a covariância e demais momentos do conjunto transformado podem ser entendidos como a estimativa da transformação não linear da distribuição original [10]. As Figura 2.1 e Figura 2.2 ilustram este conceito. A função não linear é aplicada a cada ponto sigma escolhido a fim de se obter os pontos transformados. Uma ponderação destes pontos transformados é calculada para se formar uma estimativa da média e da variância da transformação não-linear.




Figura 2.1: Princípio da transformada da Incerteza (*Unscented Transform*) [10]




Figura 2.2: Princípio da UT aplicada a uma distribuição Gaussiana

Seja $w(\hat{u})$ uma função densidade de probabilidade contínua de uma variável aleatória e seja w_i uma função densidade de probabilidade discreta que se relaciona com $w(\hat{u})$ através de uma transformação ou mapeamento não linear. Com esta transformação não linear definida pela UT é possível obter uma aproximação dos momentos de $w(\hat{u})$ a partir dos momentos de w_i . A UT faz com que a distribuição discreta possua os mesmos momentos da distribuição contínua após a transformação ou mapeamento não-linear, de acordo com a seguinte Equação [18]:

$$E_d\{\hat{u}^k\} = \int_{-\infty}^{+\infty} \hat{u}^k w(\hat{u}) d\hat{u} = \sum_i w_i S_i^k \quad (2.1)$$

onde,

- E_d é o valor esperado da distribuição discreta;
- \hat{u} representa o conjunto de variáveis aleatórias, com distribuição de probabilidade conhecida;
- $\int_{-\infty}^{+\infty} \hat{u}^k w(\hat{u}) d\hat{u}$ é o valor esperado E_c da distribuição contínua;
- S_i são os pontos sigma da UT;
- k é a ordem de aproximação desejada;
- w_i são definidos como pesos da UT, além de ser a função densidade de probabilidade discreta.

Em [18] é apresentada a formulação matemática descrita para a UT onde pode-se verificar utilizando a expansão em séries de Taylor que as duas distribuições (contínua e discreta) levam ao mesmo mapeamento não-linear.

2.3 DETERMINAÇÃO DOS PONTOS SIGMA

A ideia da *Unscented Transform* (UT), técnica proposta inicialmente em [10], é determinar um conjunto finito de pontos, denominados pontos-sigma (*sigma points*), que aproximam esta soma quando ponderados pelos pesos devidos. Os pontos sigma não são escolhidos aleatoriamente, são calculados deterministicamente de forma a ter propriedades específicas:

- Precisam ter uma média, uma variância ou quaisquer outros momentos previamente conhecidos.
- O conjunto de pontos sigma S_i consiste de $p + 1$ vetores e são ponderados com pesos w_i individualmente associados. Estes pesos podem ser negativos ou

positivos, mas para fornecer uma estimativa correta, deve obedecer a condição dada por [10]:

$$\sum_{i=0}^p W^i = 1$$

A escolha dos pontos sigma S_i e dos pesos w_i depende da distribuição de probabilidade das variáveis estocásticas envolvidas no problema [11]. Para uma distribuição gaussiana $N \sim (0, \sigma^2)$, os valores dos pesos w_i e dos pontos sigma S_i estão mostrados na Tabela 2.1 para dois e três pontos sigma [11].

A Figura 2.3 ilustra a distribuição contínua e a distribuição discreta com os pontos sigma (distribuição gaussiana).

Tabela 2.1: Pontos sigma e pesos para distribuição gaussiana $N \sim (0, \sigma^2)$.

N	Pesos (w_i)	Pontos sigma (S_i)
2	1/2; 1/2	$-\sigma$; σ
3	1/6; 2/3; 1/6	$-\sqrt{3}\sigma$; 0 ; $\sqrt{3}\sigma$

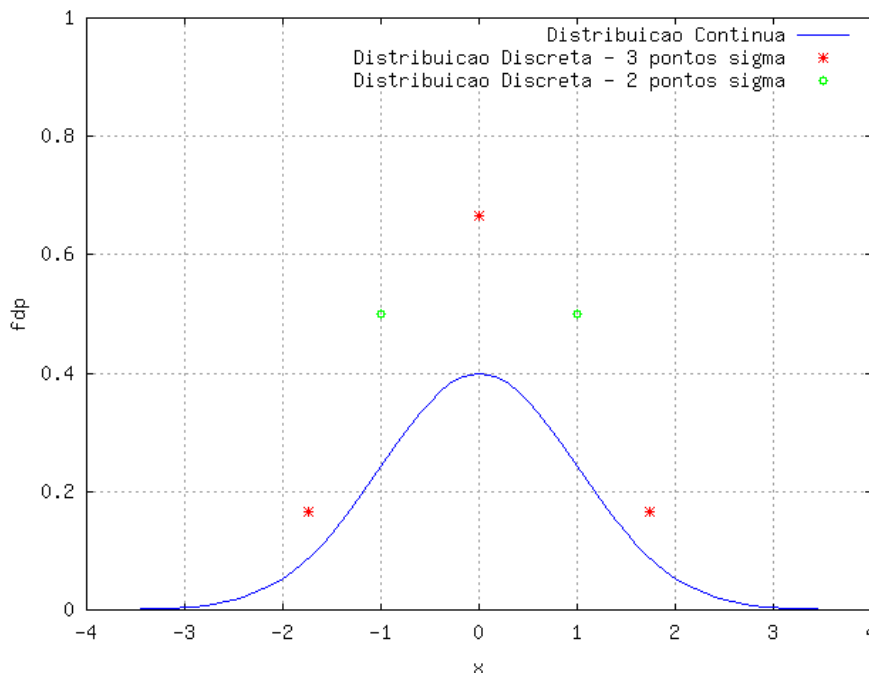


Figura 2.3: Função densidade de probabilidade contínua e a aproximação discreta [19]

Interpretando o problema de uma segunda forma, se a esperança $E\{X\}$ é a área A sob a curva $x \cdot f_x(x)$, o problema da *Unscented Transform* é determinar um conjunto finito de

retângulos R_i cuja base sejam os pesos e as alturas os valores de f_x avaliada nos pontos-sigma, tais que

$$\bigcup_i R_i \approx A \quad (2.2)$$

Em [10][20] tem-se uma formulação para a escolha dos pontos-sigma e dos pesos. Esta formulação utiliza uma aproximação da solução ideal do problema de quadraturas, assim, a escolha dos pontos-sigma e dos pesos, extrapola os pesos e os pontos-sigma de uma distribuição uniforme para as demais distribuições [19]. Pesos e pontos sigma para diferentes distribuições podem ser encontrados em [19][20][21].

2.4 TABELAS DE PONTOS SIGMA E PESOS DA UT

A Tabela 2.2 mostra os valores de pontos sigma (S_i) e pesos (w_i) para uma distribuição Gaussiana normalizada com média zero e desvio padrão 1. Para uma distribuição Gaussiana com média μ e desvio padrão σ , os pontos sigma deverão ser multiplicados por σ e somados de μ .

Tabela 2.2: Pontos sigma e pesos para distribuição gaussiana $N \sim (\mu = 0, \sigma = 1)$.

N	Pontos Sigma (S_i)	Pesos (w_i)	N	Pontos Sigma (S_i)	Pesos (w_i)
1	0	1	5	-2,8570	0,0113
2	-1	0,5		-1,3556	0,2221
	1	0,5		0,0000	0,5333
3	-1,7321	0,1667		1,3556	0,2221
	0,0000	0,6667		2,8570	0,0113
	1,7321	0,1667	6	-3,3243	0,0026
4	-2,3344	0,0459		-1,8892	0,0886
	-0,7420	0,4541		-0,6167	0,4088
	0,7420	0,4541		0,6167	0,4088
	2,3344	0,0459		1,8892	0,0886
				3,3243	0,0026

A Tabela 2.3 mostra os valores de pontos sigma (S_i) e pesos (w_i) para uma distribuição uniforme normalizada no intervalo $[-1, 1]$. Para uma distribuição uniforme no intervalo $[a, b]$, os pontos sigma deverão ser multiplicados por δ e somados de $(a + \delta)$, onde $\delta = \left(\frac{a+b}{2}\right)$.

Tabela 2.3: Pontos sigma e pesos para distribuição uniforme $U(-1, +1)$.

N	Pontos Sigma (Si)	Pesos (wi)
1	0	1
2	-0,5774	0,5
	0,5774	0,5
3	-0,7746	0,2778
	0	0,4444
	0,7746	0,2778
4	-0,8611	0,1739
	-0,34	0,3261
	0,34	0,3261
	0,8611	0,1739

N	Pontos Sigma (Si)	Pesos (wi)
5	-0,9062	0,1185
	-0,5385	0,2393
	0	0,2844
	0,5385	0,2393
	0,9062	0,1185
6	-0,9325	0,0857
	-0,6612	0,1804
	-0,2386	0,234
	0,2386	0,234
	0,6612	0,1804
	0,9325	0,0857

2.5 CRITÉRIO DE PARADA DA UT

Na teoria pode-se ter quantos pontos sigma forem necessários, no entanto aplicações práticas utilizam menos do que 10 pontos sigma [19]. Quanto mais pontos sigma utilizados maior a precisão em casas decimais do resultado como pode ser observado na Tabela 2.4. Quanto maior a ordem do momento estatístico que se deseja obter também deverá ser maior a quantidade de pontos sigma necessários. O critério de parada para se decidir quantos pontos sigma utilizar pode ser verificado pela precisão nos momentos estatísticos que se deseja obter. A medida que se aumenta a quantidade de pontos sigma da UT percebe-se que os valores dos momentos se repetem para uma certa quantidade de casas decimais. No exemplo da Tabela 2.4 tem-se o resultado de cálculo de média, desvio padrão e variância de um problema estatístico extraído de [22] que não utilizou a UT e estes valores são comparados com a UT utilizando 2 e 4 pontos sigma. Nesta tabela os valores para o caso da UT foram arredondados considerando com um erro menor do que 10^{-6} . Observa-se que ao se comparar os resultados com 2 e 4 pontos sigma os valores se repetem para 5 casas decimais na média e para 4 casas decimais no desvio padrão. Pode-se concluir que esta repetição significa que a precisão foi alcançada para esta quantidade de casas decimais e isto pode ser confirmado ao se comparar com os valores dos momentos para o cálculo sem a UT.

Tabela 2.4: Exemplo de critério de parada de acordo com a precisão dos momentos

	UT com 2 pontos Sigma	UT com 4 pontos Sigma	Resposta do Exemplo
Média	0,649914	0,649915	0,6499
Desvio Padrão	0,015058	0,015068	0,015
Variância	2,267359e-04	2,270335e-04	2,25e-04

2.6 APLICAÇÕES DA UT EM TELECOMUNICAÇÕES

A UT tem sido aplicada em diversos problemas de telecomunicações mostrando resultados com menor esforço computacional e mesma precisão [11][15][16][20]. Em [17] é apresentada uma comparação entre UT e Monte Carlo para calcular a interferência entre sistemas de telecomunicações e seus resultados serão resumidos a seguir como exemplo prático das vantagens da UT.

Uma small cell LTE-Advanced transmitindo em 3560-3600 MHz interfere em um receptor de TVRO de um sistema via satélite em 3625-3631 MHz. Os receptores estão espalhados ao redor da estação base mantendo uma distância mínima de 20m e uma distância máxima de 150m. Os parâmetros de simulação estão apresentados na Tabela 2.5.

Tabela 2.5: Parâmetros utilizados na simulação [17]

Estação base LTE		TVRO	
Parâmetros	Valores	Parâmetros	Valores
Raio	150 m	Altura	6 m
Altura	6 m	Antena ganho na direção da estação base	-10 dBi
Número de setores	1	Faixa de Frequência	3625-3631 MHz
Inclinação da Antena	0º	Distância Mínima da estação base LTE	20 m
Faixa de Frequência	3560-3600 MHz	Distância Máxima da estação base LTE	150 m
EIRP	37 dBm	Limiar de <i>Overload</i> (O_{th})	-60 dBm
Máscara Espectral	3GPP		
Ganho da Antena	5dBi		
Diagrama da Antena	Omni direcional		

O modelo de propagação de propagação para este ambiente pode ser descrito por [17]:

$$PL(dB) = PL_{LOS} \cdot p_{LOS}(d) + PL_{NLOS} \cdot [1 - p_{LOS}(d)] + G \quad (2.3)$$

onde,

$$PL_{LOS} = 42,93 + 20 \cdot \log_{10}(d) \quad (2.4)$$

$$PL_{NLOS} = 33,5 + 40 \cdot \log_{10}(d) \quad (2.5)$$

$$p_{LOS}(d) = \left\{ 1 + \frac{1}{\exp[-0,1 \cdot (d-70)]} \right\}^{-1} \quad (2.6)$$

d é a distância entre o transmissor e o receptor em metros, G é uma variável randômica gaussiana com média zero e desvio padrão 3,89dB. Este problema tem 3 variáveis aleatórias: a posição do receptor TVRO em coordenadas polares, representado pelo azimute (θ) e pela distância d , e a variável de propagação G . As variáveis d e θ , são distribuições uniformes variando no intervalo [20, 150] metros e [0, 360] graus respectivamente. No cálculo da interferência foram considerados o ACLR (*adjacent channel leakage ratio*) provocado pela transmissão da estação base fora da banda e o ACS (*adjacent channel selectivity*) provocado pela baixa seletividade do filtro de recepção do TVRO [17]. O limiar total desta interferência que causa bloqueio no receptor TVRO (Pr_{blocking}) é de -60dBm que representa o valor do limiar de *overload* (O_{th}).

As simulações com a UT foram feitas usando 5x5x3 e 8x8x3 pontos sigma, onde esta sequência de 3 números representa a quantidade de pontos sigma das distribuições da distância d , do azimute (θ) e da variável G , ou seja, um total de 75 e 192 eventos de simulação foram realizados com a UT. Na simulação de Monte Carlo foram usados 1.000, 10.000, 100.000 e 1.000.000 de eventos. A Figura 2.4 apresenta o cenário de simulação com Monte Carlo e com a UT. O ponto preto ao centro representa a estação base LTE e os demais pontos em cinza representam os receptores TVRO.

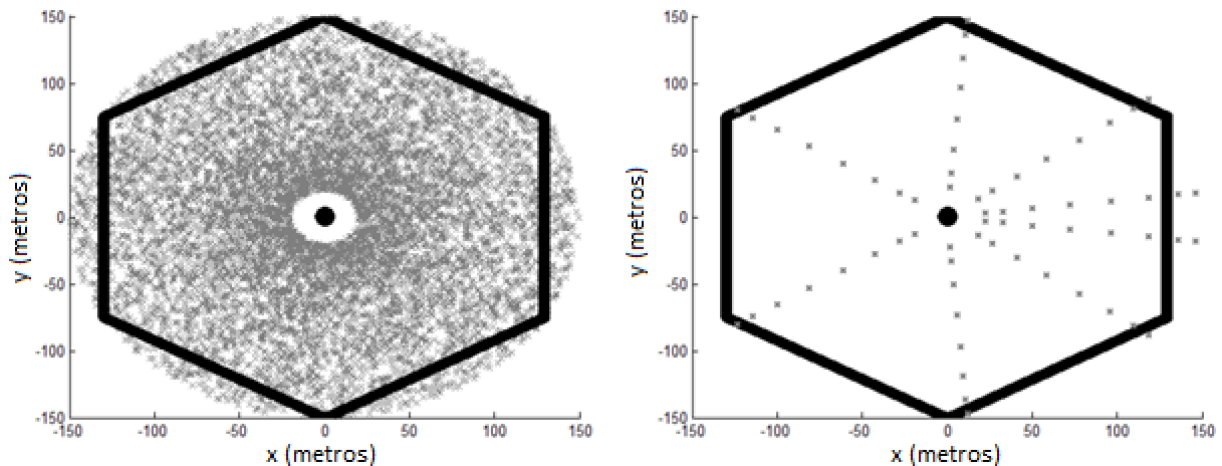


Figura 2.4: Simulação com MC (esquerda) e a simulação com UT (direita) [17]

Na Figura 2.5 à esquerda são mostradas as 3 variáveis de entrada e no lado direito o resultado de cdf da potência de bloqueio (Pr_{blocking}) com 1.000.000 de eventos em MC enquanto a UT usou 75 e 192 eventos.

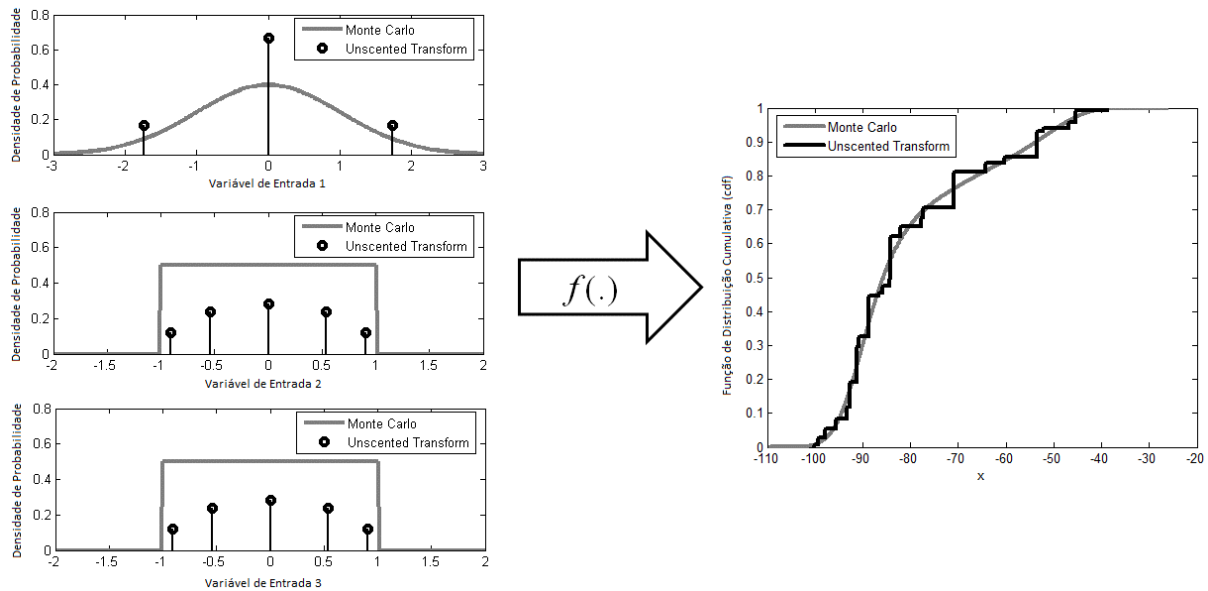


Figura 2.5: Simulações usando MC e UT [17]

A Tabela 2.6 mostra o comparativo estatístico entre MC e a UT para diferentes quantidades de eventos. Pode-se observar que a UT 8x8x3 obteve resultados similares a MC com 1.000.000 de eventos.

Tabela 2.6: Resultados obtidos da simulação [17]

	MC 1,000,000	MC 100,000	MC 10,000	MC 1,000	UT 5x5x3	UT 8x8x3
Média (dB)	-80.04	-79.99 (0.06%)	-80.32 (0.3%)	-79.07 (1.2%)	-80.12 (0.1%)	-80.06 (0.02%)
Desvio Padrão (dB)	15.16	15.23 (0.5%)	15.04 (0.8%)	15.81 (4.3%)	14.87 (1.9%)	15.15 (0.1%)
Assimetria (Skewness)	1.03	1.03 (0.0%)	1.06 (2.9%)	0.89 (13.6%)	1.02 (1.0%)	1.04 (1.0%)
Curtose	2.96	2.92 (1.4%)	3.04 (2.7%)	2.57 (13.2%)	3.07 (3.7%)	2.97 (0.3%)
$Pr_{blocking} < O_{th}$ (%)	84.54	84.38 (0.2%)	84.9 (0.4%)	82 (3.0%)	88.15 (4.3%)	85.67 (1.3%)

2.7 CONSIDERAÇÕES FINAIS DA UT

A Transformada da Incerteza (UT) apresenta vantagens em termos de diminuição de tempo de processamento computacional e de redução de quantidade de amostras necessárias para obtenção de resultados estatísticos de variáveis aleatórias conforme exemplo apresentado anteriormente. Estas vantagens justificam a utilização desta transformada na análise de propagação em vegetação que é objeto do estudo desta tese.

3 COMPATIBILIZAÇÃO ENTRE O TEOREMA DE BAYES E TRANSFORMADA DA INCERTEZA

3.1 FUNDAMENTOS DO TEOREMA DE BAYES

A inferência Bayesiana é o processo de ajustar um modelo de probabilidade a um conjunto de dados existentes ou observados. O resultado é resumido por uma distribuição de probabilidade baseada nos parâmetros do modelo, permitindo previsões sobre novas observações de dados. A análise de dados utilizando o teorema de Bayes permite fazer inferências estatísticas e quantificar incertezas usando modelos de probabilidade de informações conhecidas e modelos de probabilidade de informações sobre as quais se quer aprender. O processo da análise de dados utilizando Bayes pode ser dividido em três passos [22][23]:

1. Como premissa para se fazer uma inferência, deve existir um modelo completo de probabilidade que traduza o conhecimento que se tem do experimento em estudo. Este modelo é descrito por uma distribuição de probabilidade conjunta, denominada $p(\theta, y)$, formada por todas as informações conhecidas e por todas as informações sobre as quais se quer conhecer, representada pela variável y e θ , respectivamente.
2. Análise condicional resultante do cálculo e interpretação da distribuição a *posteriori*, denominada $p(\theta | y)$. O objetivo da inferência de Bayes é obter a distribuição de probabilidade condicional das informações sobre as quais se quer conhecer, dado que já existiam informações conhecidas.
3. Pela análise da distribuição *posteriori* obtida é possível decidir se o modelo precisa de correções. As conclusões obtidas pelo modelo devem ser coerentes com as informações conhecidas e não conhecidas. Caso a distribuição *posteriori* obtida não seja coerente, pode ser necessário alterar ou expandir o modelo e depois repetem-se estes 3 passos. O modelo de probabilidade conjunta pode, inicialmente, ser incoerente por ser incompleto com o objetivo de verificar se uma solução mais simples do problema é suficiente. Existem modelos que podem ser analisados com apenas uma variável ou com múltiplas

variáveis, ou ainda modelos complexos com múltiplas camadas hierárquicas de probabilidade.

A forma Bayesiana de pensar é mais intuitiva tornando as conclusões estatísticas mais simples de entender. A mente pode ser considerada uma máquina de inferência que constantemente constrói hipóteses para explicar ou prever incertezas. Por exemplo, seja um intervalo de estimação para um parâmetro qualquer θ . O intervalo Bayesiano (probabilidade) trata o parâmetro θ como aleatório e cria uma distribuição de valores possíveis de θ , visto que existem informações anteriores sobre θ . O intervalo frequentista trata o parâmetro θ como fixo e os limites deste intervalo é baseado em estatísticas de um conjunto de informações que garantem que existe uma probabilidade de que o intervalo contenha o parâmetro θ . Em geral, a intuição das pessoas para intervalos de estimação estão mais alinhadas com o intervalo Bayesiano. É usual se pensar que existe uma alta ou baixa probabilidade de que um parâmetro θ pertence a um determinado intervalo, e isto é uma forma Bayesiana de pensar. Esta interpretação trata os limites do intervalo como fixo e o parâmetro θ como aleatório [23]. “Recentemente, nas estatísticas aplicadas, uma maior ênfase foi colocada na estimativa do intervalo do que no teste de hipóteses. Isso fornece um forte ímpeto para o ponto de vista Bayesiano, uma vez que aparentemente a maioria dos usuários de intervalos de confiança está dando a estes intervalos uma interpretação Bayesiana de senso comum” [22].

3.2 INFERÊNCIA BAYESIANA

O conhecimento sobre determinado parâmetro pode ser entendido como uma distribuição de probabilidade que prevê o resultado deste parâmetro. Este conhecimento pode ter grande precisão, de forma que a distribuição de probabilidade é concentrada sobre o resultado mais provável – a média ou expectativa. Isto significa que a precisão, ou inverso da variância, corresponde a confiança ou certeza associada ao conhecimento deste parâmetro. Na inferência Bayesiana, conhecimentos prévios obtidos são representados pela distribuição *priori*, o qual serão atualizados pelas novas evidências da distribuição amostral de forma a se obter a distribuição *posteriori* [22][24].

Inferência estatística busca obter conclusões sobre dados ainda não observados em um experimento. Para isto utiliza conhecimentos prévios do modelo que explica o experimento, o qual é baseado em dados coletados anteriormente no experimento, em conjunto com novas evidências amostrais coletadas. Estes dados podem ser coletados analiticamente ou empiricamente. Por exemplo, seja um experimento em que se deseja estimar o nível de sinal

recebido por usuários de serviço móvel celular de uma determinada operadora celular em uma determinada região.

Utiliza-se um modelo de propagação previamente conhecido que é baseado em uma distribuição de amostras de dados empíricos medidos em campo em algum outro experimento similar combinado com cálculos analíticos que explicam os efeitos físicos de propagação de uma onda eletromagnética. Este conhecimento seria a distribuição *a priori*. Com este modelo pode-se estimar o nível de sinal recebido em lugares em que não foram feitas medições em campo. No entanto, pode-se aumentar a precisão desta estimativa caso novas medições amostrais coletadas na região que se deseja estimar o nível de sinal sejam utilizadas para atualizar o modelo. Estas novas medições representam a distribuição amostral e o resultado da atualização do modelo é a distribuição *a posteriori* [23].

Qual a probabilidade de ocorrer um evento θ dado um conjunto de eventos y que já foram observados? Combinam-se duas probabilidades: a probabilidade de que o evento y tenha ocorrido dado que o evento θ ocorreu, ou seja, qual a verossimilhança entre eles; e a probabilidade já conhecida de que os eventos y tenham ocorrido. Esta combinação é uma multiplicação destas duas probabilidades, e o resultado é a probabilidade *posteriori* no teorema de Bayes, ou é a inferência do evento θ . A inferência sobre as chances de algo acontecer é resultado da combinação das chances de que este “algo” seja semelhante a outra evidência conhecida multiplicado pela probabilidade de ocorrência desta evidência conhecida.

A distribuição *priori* representa (probabilisticamente) o conhecimento que se tem sobre θ antes da realização do experimento, ou seja, antes de se ter conhecimento do valor do evento y . Seja θ o parâmetro do qual se deseja fazer uma inferência. A informação já disponível sobre θ permite associar a ele uma distribuição de probabilidade que descreverá as incertezas e crenças de um pesquisador, chamada distribuição *à priori*. A Figura 3.1 compara diferentes graus de certeza para distribuição *priori*.

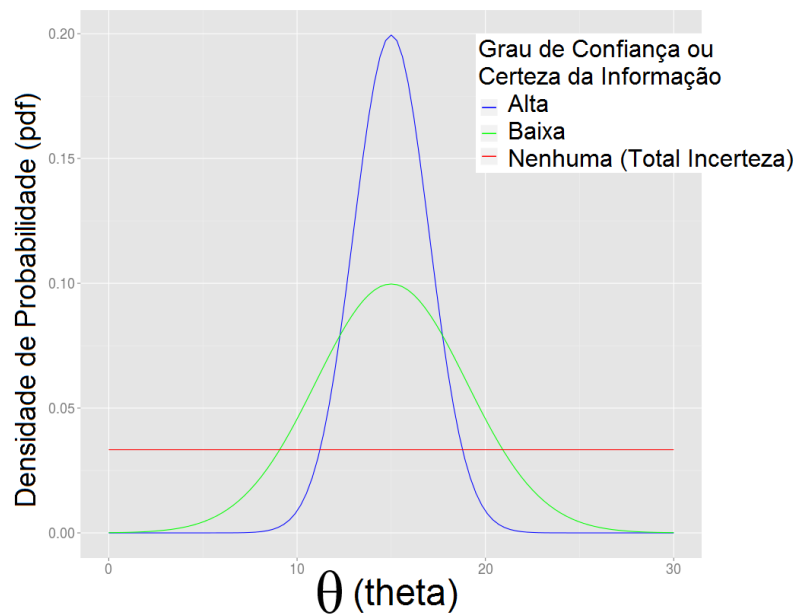


Figura 3.1: Formas da distribuição *priori* para diferentes graus de certeza

A distribuição amostral (*sampling*) fornece, para um valor y , a verossimilhança de cada um dos possíveis valores de θ , ou seja, a probabilidade de observar θ dado que o evento y aconteceu. Indica a verossimilhança ou a compatibilidade de uma evidência y com uma hipótese θ . Esta distribuição é responsável por trazer novas evidências para o modelo representado pela distribuição *priori* de forma a atualizá-lo. O modelo atualizado pela distribuição amostral é a distribuição *posteriori*.

Na diagramação da Figura 3.2 são mostradas distribuições gaussianas que representam as distribuições *priori*, amostral e *posteriori* para algum parâmetro θ qualquer. É possível analisar o impacto que a distribuição à *priori* e a amostral (verossimilhança) têm na distribuição à *posteriori*. A linha tracejada na vertical representa a média ou expectativa *posteriori* para o parâmetro θ , enquanto a largura das distribuições representa a dispersão ou variância. A precisão na distribuição é o inverso da dispersão e alterações na precisão da *priori* ou da amostral produzem um profundo impacto na distribuição *posteriori*. A distribuição *posteriori* tende em direção à distribuição *priori* à medida que aumenta sua precisão relativa e o mesmo acontece com a distribuição amostral. Isto significa, por exemplo, que a expectativa da *posteriori* pode ser tendenciosa em relação à evidência amostral, quer aumentando a precisão da amostral ou diminuindo a precisão da *priori* [22][23].

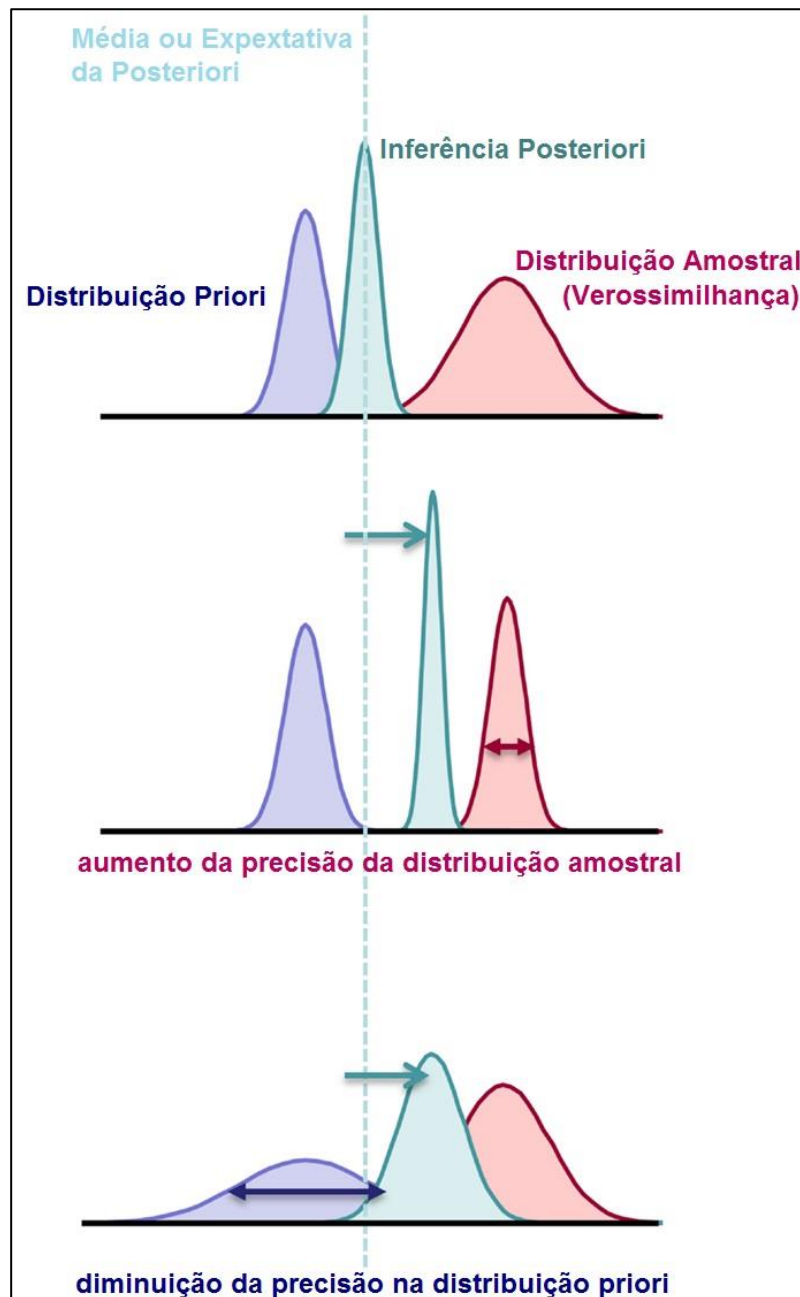


Figura 3.2: Influência das distribuições *Priori* e Amostral na *Posteriori*

Pode-se agora definir estas distribuições de forma matemática e como elas se relacionam dentro do teorema de Bayes. Seja um parâmetro θ que define um evento ou parâmetro a ser estudado em um experimento, por exemplo, estimar a atenuação provocado pelo efeito do espalhamento em um ambiente de vegetação. O teorema da inferência de Bayes define como obter conclusões estatísticas sobre este parâmetro θ em termos de probabilidades de θ condicionadas pelo valor observado y , ou seja, $p(\theta|y)$. Antes de se definir a inferência de uma variável θ dado y , é necessário ser definido o modelo da probabilidade de distribuição conjunta de θ e y , ou seja, $p(\theta, y)$. Esta distribuição é formada por todas as informações conhecidas de ocorrência do evento y e por todas as informações do evento θ sobre o qual se

quer conhecer. A função densidade de probabilidade conjunta pode ser escrita como o produto das seguintes densidades definidas pelo teorema de Bayes: distribuição a *priori* $p(\theta)$ e distribuição amostral $p(y|\theta)$ [22][23]:

$$p(\theta, y) = p(\theta) * p(y|\theta) \quad (3.1)$$

A distribuição a *posteriori* é obtida ao se aplicar a regra de Bayes de probabilidade condicional sobre a distribuição conjunta, ou seja, condiciona-se a distribuição conjunta em relação aos valores conhecidos de y :

$$p(\theta|y) = \frac{p(\theta, y)}{p(y)} = \frac{p(\theta) * p(y|\theta)}{p(y)} \quad (3.2)$$

A distribuição $p(y)$, também conhecida como preditiva, pode ser discreta ou contínua. Para o caso discreto tem-se $p(y) = \sum_{\theta} p(\theta) * p(y|\theta)$, sendo este somatório sobre todos os valores possíveis de θ . Para o caso contínuo de θ tem-se $p(y) = \int p(\theta) * p(y|\theta) d\theta$ onde $p(\theta)$ é a probabilidade de todos os valores possíveis de $p(y|\theta)$. Utilizando esta definição de $p(y)$ tem-se que a distribuição *posteriori* pode ser escrita da forma:

$$p(\theta|y) = \frac{p(y|\theta) * p(\theta)}{\int p(\theta) * p(y|\theta) d\theta} \quad (3.3)$$

Uma forma equivalente da Equação 3.2 omite o fator $p(y)$, o qual não depende de θ e, considerando que se tem um valor y determinado, pode-se considerar $p(y)$ uma constante. No teorema de Bayes, $p(y)$ é apenas uma constante normalizadora que garante uma área sob a distribuição de probabilidades da *posteriori* igual a 1 ou que a integral da *posteriori* tem valor 1. Esta interpretação fornece uma densidade não normalizada da probabilidade *posteriori* que pode ser escrita de forma simplificada da seguinte forma:

$$p(\theta|y) \sim p(y|\theta) * p(\theta) \quad (3.4)$$

A probabilidade *posteriori* pode ser entendida como sendo proporcional à distribuição amostral multiplicada pela distribuição *priori*, ou seja, ambos os lados da proporcionalidade têm uma curva com a mesma forma. As equações 3.1 à 3.4 resumem as questões técnicas da inferência de Bayes de qualquer aplicação específica que são: desenvolver o modelo conjunto $p(\theta, y)$ e executar os cálculos para se obter $p(\theta|y)$ de forma adequada [22]. O teorema de Bayes pode ser considerado uma metodologia para atualização contínua de um modelo conhecido, onde a cada nova evidência amostral se calcula uma nova distribuição *posteriori*. Esta distribuição *posteriori* calculada se tornará a distribuição *priori* a ser utilizada quando um novo conjunto de novas amostras forem coletadas. Os termos *priori* e *posteriori* enfatizam o conceito de uma aprendizagem sequencial [23].

Para realizar inferências sobre uma observação desconhecida, frequentemente chamada inferência preditiva, usa-se uma lógica similar, ou seja, é a distribuição esperada

para a observação de y dado θ . Antes do dado y ser observado, a distribuição dos dados desconhecidos mas observáveis y é:

$$p(y) = \int p(y, \theta) d\theta = \int p(\theta) * p(y|\theta) d\theta \quad (3.5)$$

Esta forma de interpretação é frequentemente chamada distribuição marginal de y , mas uma designação mais explicativa é distribuição preditiva *a priori*. É *priori* porque não é condicionada a uma observação anterior do processo, e é preditiva porque é uma distribuição de uma quantidade observável.

Os dados de y afetam a inferência posterior somente através de $p(y|\theta)$, como pode ser visto na Equação 3.4, que, quando considerada em um determinado modelo de probabilidade como uma função de θ , para y fixo, é chamada função de verossimilhança, ou *likelihood*, ou *sampling*. [22].

3.3 APLICAÇÃO DA TRANSFORMADA DA INCERTEZA AO TEOREMA DE BAYES

No teorema da inferência de Bayes a distribuição *a posteriori* é obtida pela multiplicação entre a distribuição *a priori* e a distribuição de amostras (*sampling*). A multiplicação de distribuições UT com pontos sigma diferentes não está disponível no estado da arte. Neste trabalho foi desenvolvido uma técnica que consiste em calcular novas distribuições que tenham os mesmos pontos sigma e assim a multiplicação da equação 3.1 pode ser calculada.

Na Figura 3.3 existe um bloco para cálculo dos “novos pontos sigma comuns” visto que esta condição é necessária para permitir a multiplicação da UT *priori* pela UT *sampling*. As Equações 3.6 e 3.7 detalham a metodologia utilizada para se aplicar as transformadas UT das distribuições *priori* e da *sampling* no cálculo da inferência de Bayes. Esta técnica calcula novas distribuições UT da *priori* e da *sampling* as quais terão novos pontos sigma comuns (S_m), diferentes pesos (p_m), mas mantendo os mesmos valores dos momentos estatísticos das distribuições anteriores. A multiplicação das distribuições UT, conforme mostrado no lado direito da Figura 3.3, será possível porque ambas as distribuições terão os mesmos pontos sigma (S_m). Os pesos destas novas distribuições são calculados de forma que os momentos estatísticos sejam preservados.

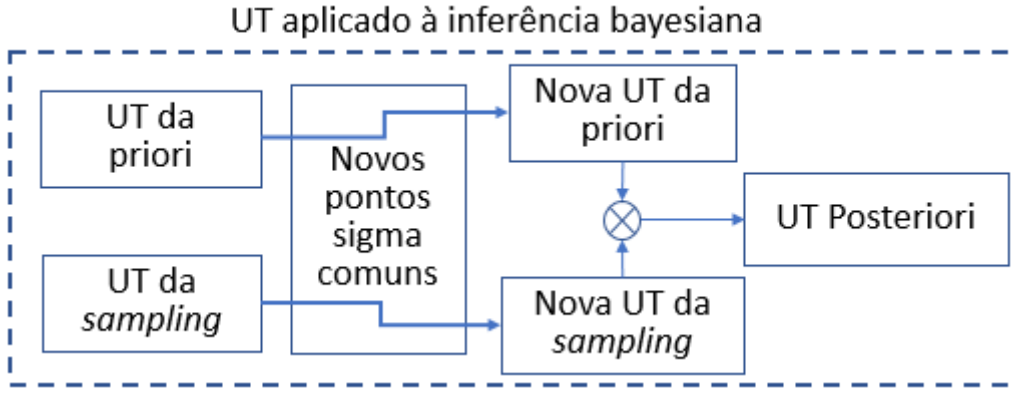


Fig. 3.3: Método de multiplicação de UTs aplicado na inferência bayesiana

As Equações 3.6 e 3.7 mostram como as novas distribuições *priori* e *sampling* se relacionam com os pontos sigma (S_i e S_q) e pesos (p_i e p_q) anteriores. Como são obtidos pontos sigma (S_m) iguais para ambas as distribuições *priori* e *sampling* então a Equação 3.1 pode ser calculada. A quantidade de momentos utilizados nas Equações 3.6 e 3.7 dependerá de quantos pontos sigma são necessários nas distribuições.

$$\sum_{i=1}^N p_i * S_i^k = \sum_{m=1}^N p'_m * S_m^k = E\{x_1^k\} \quad (3.6)$$

$$\sum_{q=1}^N p_q * S_q^k = \sum_{m=1}^N p''_m * S_m^k = E\{x_2^k\} \quad (3.7)$$

Como exemplo pode-se desenvolver estas equações 3.6 e 3.7 para o caso de uma *posteriori* UT com três pontos sigma:

$$p_{i1} * S_{i1}^0 + p_{i2} * S_{i2}^0 + p_{i3} * S_{i3}^0 = p'_{m1} * S_{m1}^0 + p'_{m2} * S_{m2}^0 + p'_{m3} * S_{m3}^0 = E\{x_1^0\} = 1 \quad (3.8)$$

$$p_{i1} * S_{i1}^1 + p_{i2} * S_{i2}^1 + p_{i3} * S_{i3}^1 = p'_{m1} * S_{m1}^1 + p'_{m2} * S_{m2}^1 + p'_{m3} * S_{m3}^1 = E\{x_1^1\} = \text{média}(x_1) \quad (3.9)$$

$$p_{i1} * S_{i1}^2 + p_{i2} * S_{i2}^2 + p_{i3} * S_{i3}^2 = p'_{m1} * S_{m1}^2 + p'_{m2} * S_{m2}^2 + p'_{m3} * S_{m3}^2 = E\{x_1^2\} = \text{variância}(x_1) \quad (3.10)$$

$$p_{i1} * S_{i1}^3 + p_{i2} * S_{i2}^3 + p_{i3} * S_{i3}^3 = p'_{m1} * S_{m1}^3 + p'_{m2} * S_{m2}^3 + p'_{m3} * S_{m3}^3 = E\{x_1^3\} = \text{Skewness}(x_1) \quad (3.11)$$

$$p_{i1} * S_{i1}^4 + p_{i2} * S_{i2}^4 + p_{i3} * S_{i3}^4 = p'_{m1} * S_{m1}^4 + p'_{m2} * S_{m2}^4 + p'_{m3} * S_{m3}^4 = E\{x_1^4\} = \text{kurtosis}(x_1) \quad (3.12)$$

$$p_{i1} * S_{i1}^5 + p_{i2} * S_{i2}^5 + p_{i3} * S_{i3}^5 = p'_{m1} * S_{m1}^5 + p'_{m2} * S_{m2}^5 + p'_{m3} * S_{m3}^5 = E\{x_1^5\} \quad (3.13)$$

$$p_{q1} * S_{q1}^0 + p_{q2} * S_{q2}^0 + p_{q3} * S_{q3}^0 = p''_{m1} * S_{m1}^0 + p''_{m2} * S_{m2}^0 + p''_{m3} * S_{m3}^0 = E\{x_2^0\} = 1 \quad (3.14)$$

$$p_{q1} * S_{q1}^1 + p_{q2} * S_{q2}^1 + p_{q3} * S_{q3}^1 = p''_{m1} * S_{m1}^1 + p''_{m2} * S_{m2}^1 + p''_{m3} * S_{m3}^1 = E\{x_2^1\} = \text{média}(x_2) \quad (3.15)$$

$$p_{q1} * S_{q1}^2 + p_{q2} * S_{q2}^2 + p_{q3} * S_{q3}^2 = p''_{m1} * S_{m1}^2 + p''_{m2} * S_{m2}^2 + p''_{m3} * S_{m3}^2 = E\{x_2^2\} = \text{variância}(x_2) \quad (3.16)$$

$$p_{q1} * S_{q1}^3 + p_{q2} * S_{q2}^3 + p_{q3} * S_{q3}^3 = p''_{m1} * S_{m1}^3 + p''_{m2} * S_{m2}^3 + p''_{m3} * S_{m3}^3 = E\{x_2^3\} = \text{Skewness}(x_2) \quad (3.17)$$

$$p_{q1} * S_{q1}^4 + p_{q2} * S_{q2}^4 + p_{q3} * S_{q3}^4 = p''_{m1} * S_{m1}^4 + p''_{m2} * S_{m2}^4 + p''_{m3} * S_{m3}^4 = E\{x_2^4\} = \text{kurtosis}(x_2) \quad (3.18)$$

A quantidade de equações necessárias para resolver o sistema das Equações 3.6 e 3.7 vai depender da quantidade de pontos sigma que se quer calcular e da precisão dos momentos estatísticos que se quer obter na distribuição UT *posteriori*. A Tabela 3.1 relaciona a quantidade de equações e momentos necessários de acordo com a quantidade de pontos sigma requeridos. A quantidade total de equações necessárias será obtida da soma da quantidade de equações da distribuição *prior* e da distribuição *sampling*, sendo que para cada equação ser gerada é necessário o cálculo do respectivo momento estatístico. No entanto, quando a quantidade de pontos sigma por distribuição for ímpar o sistema terá 1 equação a mais do que o número de incógnitas ($S_m + p_i + p_q$). Neste caso recomenda-se, de forma a simplificar a resolução do sistema, que se elimine 1 das equações onde se usa o momento de ordem zero, por exemplo, a equação 3.8 ou 3.14 do exemplo anterior.

Tabela 3.1: Quantidade de equações e momentos de acordo com a quantidade de pontos sigma

Pontos Sigma da <i>Posteriori</i> (S_m)	Novos Pesos da UT <i>Prior</i> (p_i)	Novos Pesos da UT <i>Sampling</i> (p_q)	Quantidade de Equações ($S_m + p_i + p_q$)	Momentos por distribuição <i>Sampling</i> ou <i>Prior</i>
2	2	2	6	3
3	3	3	9	5
4	4	4	12	6
5	5	5	15	8
6	6	6	18	9
n	n	n	3n	Arredondar para cima ($3n/2$)

Pode-se aplicar o conjunto de equações 3.8 a 3.18 em duas distribuições binomiais. Na distribuição prior foi usada uma binomial $\text{Bin}(n=1000; p=0,5)$ e a na distribuição *sampling* foi usada uma binomial $\text{Bin}(n=1000; p=0,65)$.




Fig. 3.4: Método de multiplicação de distribuições binomiais aplicado na inferência bayesiana

O objetivo agora é resolver este mesmo caso pelo teorema de Bayes aplicando a UT. Como resultado obteve-se as distribuições UT prior e *sampling* em tracejado na Figura 3.5 e a distribuição UT *posteriori* na Figura 3.6. A metodologia desenvolvida nesta tese define que a Transformada da Incerteza (UT) aplicado ao Teorema de Bayes pode ser aplicada na distribuição *priori* e na distribuição amostral desde que os pontos sigma de ambas as distribuições sejam alterados para pontos sigma comuns ou sejam condicionados a serem pontos comuns conforme Equações 3.6 e 3.7.

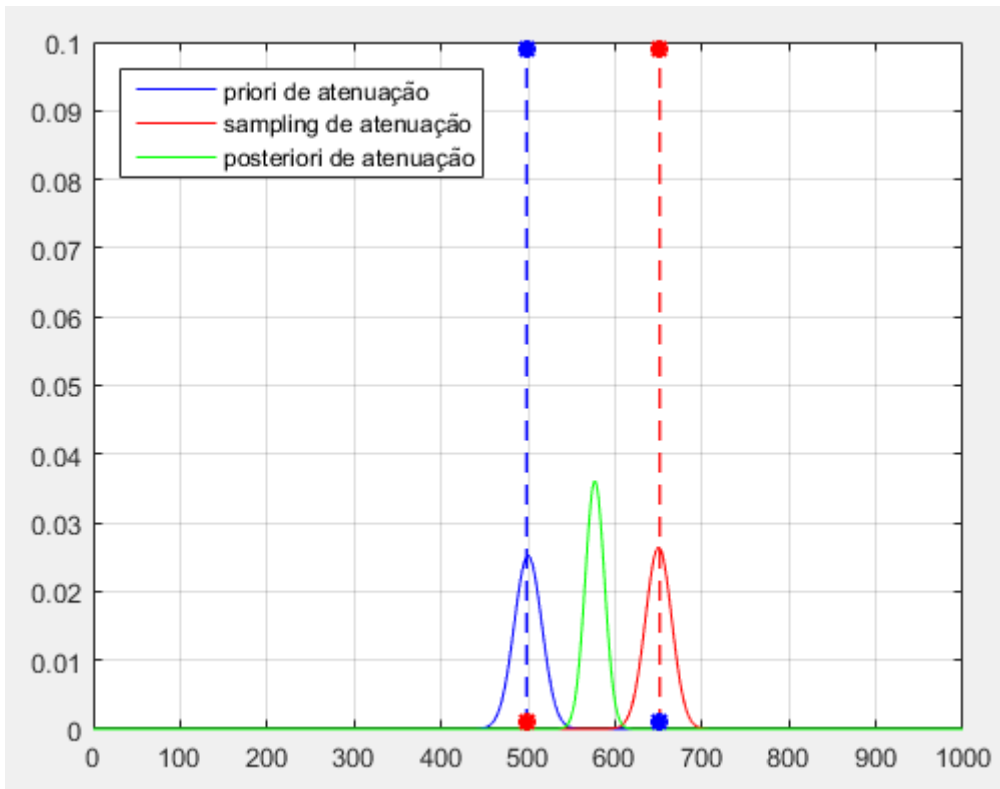


Fig. 3.5: Distribuição UT da Prior e *Sampling* binomial com 2 pontos sigma e respectivos pesos (linhas tracejadas)

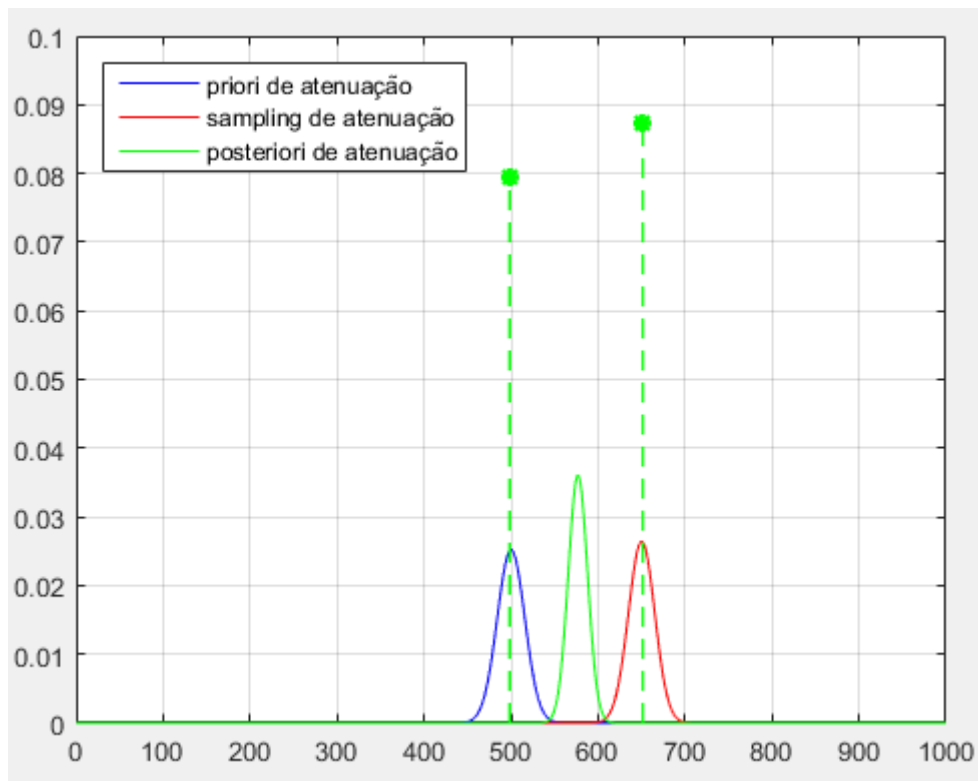


Fig. 3.6: Distribuição UT da *posteriori* binomial com 2 pontos sigma e respectivos pesos (linhas tracejadas)

De forma similar pode-se resolver o mesmo exemplo com mais pontos sigma. A seguir o mesmo caso foi resolvido com 4 pontos sigma.

Primeiramente se calculam os momentos estatísticos não centralizados da binomial usando a função de geração de momentos conforme [25]. Para uma UT com 4 pontos sigma precisa-se de 8 momentos. Para a prior tem-se $n = 1000$ e $y = 650$, e pode-se calcular os 8 momentos:

- Primeiro Momento = $1/(n+1) = 9,9900e-004$;
- Segundo Momento = $(y+1)/((n+1)*(2+n)) = 6,491e-004$;
- Terceiro Momento = $(y+1)*(y+2)/((n+1)*(2+n)*(3+n)) = 4,219e-004$;
- Quarto Momento = $(y+1)*(y+2)*(y+3)/((n+1)*(2+n)*(3+n)*(4+n)) = 2,744e-004$;
- Quinto Momento = $(y+1)*(y+2)*(y+3)*(y+4)/((n+1)*(2+n)*(3+n)*(4+n)*(n+5)) = 1,786e-004$;
- Sexto Momento = $(y+1)*(y+2)*(y+3)*(y+4)*(y+5)/((n+1)*(2+n)*(3+n)*(4+n)*(n+5)*(n+6)) = 1,163e-004$;
- Sétimo Momento = $(y+1)*(y+2)*(y+3)*(y+4)*(y+5)*(y+6)/((n+1)*(2+n)*(3+n)*(4+n)*(n+5)*(n+6)*(n+7)) = 0,757e-004$;
- Oitavo Momento = $(y+1)*(y+2)*(y+3)*(y+4)*(y+5)*(y+6)*(y+7)/((n+1)*(2+n)*(3+n)*(4+n)*(n+5)*(n+6)*(n+7)*(n+8)) = 0,494e-004$;

A partir destes momentos da distribuição amostral binomial se encontra os pontos sigma e os pesos da UT conforme a Equação 2.1. O resultado está na Figura 3.7. De forma similar se calcula os momentos para distribuição *sampling* e o resultado está na Figura 3.8.




Figura 3.7: Distribuição UT da Prior Binomial com 4 pontos sigma e respectivos pesos




Figura 3.8: Distribuição UT da *Sampling* Binomial com 4 pontos sigma e respectivos pesos

Para calcular os pontos sigma da distribuição binomial *posteriori* deve-se calcular o produto da UT prior pela UT *sampling* binomial para cada ponto sigma com seus respectivos pesos. O resultado está na Figura 3.9.




Figura 3.9: Distribuição UT da *posteriori* binomial com 4 pontos sigma e respectivos pesos




Fig. 3.10: Distribuição UT de atenuação da vegetação: *posteriori*, *priori* e *sampling* (grupo 2)

A Figura 3.10 apresenta a distribuição UT *posteriori* com 4 pontos sigma após a multiplicação das distribuições *priori* e *sampling*. Esta *posteriori* UT foi calculada utilizando a metodologia apresentada na Figura 3.3. Além do resultado apresentado nas Figuras 3.5 com 2 pontos sigma e na Figura 3.10 com 4 pontos sigma, foram calculadas diferentes distribuições UT *posteriori*, com outros pontos sigma da UT, e o cálculo do valor esperado variou menos de 1%.

3.4 CONSIDERAÇÕES FINAIS DA UT APLICADA A BAYES

O método desenvolvido para aplicar a Transformada da Incerteza (UT) ao Teorema da Inferência de Bayes obteve sucesso e o mesmo foi aplicado e validado em exemplos e exercícios do [22][26]. Este método inova no estado da arte ao apresentar uma solução para multiplicação de distribuições UTs com pontos sigma diferentes e mostra uma aplicação imediata ao permitir o cálculo da distribuição UT *posteriori* de Bayes. Este método será aplicado na análise de propagação em vegetação que é objeto do estudo desta tese.

A Tabela 3.2 apresenta uma comparação de resultados estatísticos do exemplo apresentado neste capítulo entre o cálculo da *posteriori* sem a UT e com a UT. Os valores são

próximos o suficiente e o menor esforço computacional da UT justificaria a sua adoção na metodologia proposta neste estudo. Pode-se observar que com apenas 2 pontos sigma obtêm-se um valor esperado com erro (média) de menos de 1% em relação ao cálculo sem a UT. O algoritmo que calcula a distribuição UT fixa os pontos sigma e este fato reduz a precisão da UT se refletindo no cálculo de momentos superiores como por exemplo a variância.

Tabela 3.2: Resumo comparativo de resultados com e sem a UT

	UT com 2 pontos Sigma	UT com 4 pontos Sigma	Resposta do Exemplo sem UT
Média	578.6089	572,4120	574,9251
Desvio Padrão	76,49	74,97	11,05
Variância	5850,2	5620,5	122,11

4 PROPAGAÇÃO DE ONDAS ELETROMAGNÉTICAS EM VEGETAÇÃO

4.1 ATENUAÇÃO E ESPALHAMENTO DO SINAL DEVIDO A VEGETAÇÃO

Os principais efeitos da vegetação na propagação de ondas de rádio em ambiente outdoor são modelados na literatura como uma componente não linear de atenuação devido à folhagem que é adicionada à atenuação no espaço livre. O nível do sinal diminui rapidamente nos primeiros poucos metros de propagação dentro de uma área arborizada devido à alta atenuação do enlace em visada direta, mas posteriormente decresce bem mais lentamente à medida que penetra na vegetação. Esta mudança na atenuação ocorre porque nos primeiros metros o efeito da atenuação no enlace direto é dominante e posteriormente o efeito de espalhamento passa a ser dominante, devido aos múltiplos efeitos dos diferentes espalhadores sobre a energia eletromagnética incidente [6][7]. A vegetação aumenta o número de componentes de multipercurso em faixas de frequências mais altas, devido à maior relevância dos efeitos de reflexão e do espalhamento. O número de componentes de multipercurso em cenários suburbanos com forte presença de vegetação é 1,23 vezes maior quando comparado com cenário urbanos sem vegetação [6].

Existem poucos estudos experimentais com medidas coletadas especificamente para caracterizar os efeitos da vegetação na propagação de ondas de rádio em altas frequências. Os poucos experimentos na literatura exploraram apenas o enlace em visada direta obstruído por vegetação o qual é adequado apenas para o caso de baixas frequências, visto que a difração ao redor de troncos e copas de árvores é o principal efeito na propagação. No entanto, para altas frequências, onde ocorre uma maior variação azimutal do sinal recebido devido à maior dominância de efeitos de reflexão e do espalhamento, esta forma de experimento não é adequada. Para altas frequências, uma análise direcional é mais adequada para coletar as características dos diversos multipercursos espaciais [6].

4.2 MODELOS DE ATENUAÇÃO DEVIDO A VEGETAÇÃO

A propagação em vegetação é formada pela combinação das componentes resultantes do espalhamento nas folhas e troncos, de difração no limite ou contorno da copa das árvores,

e de reflexão no solo. A vegetação é formada por um complexo conjunto de objetos dielétricos de formas arbitrárias que podem ser caracterizadas por densidade de vegetação, distribuição espacial das árvores, tamanho e orientação de galhos e folhas [27], espécies das árvores, estados sazonais de folhagem, e teor de umidade. Além destes parâmetros físicos deve-se acrescentar as características do sistema de rádio como a frequência, altura das antenas, polarização, azimute e elevação. Estão disponíveis na literatura modelos empíricos, semi-empíricos e analíticos para caracterizar os efeitos da vegetação na propagação e para estimar a atenuação que é adicionada pela vegetação sobre a atenuação do espaço livre [28][43][44][45].

4.2.1 MODELOS EMPÍRICOS

A principal vantagem dos modelos empíricos está na simplicidade das expressões matemáticas, facilitando a aplicação em casos práticos. Como desvantagem dependem de medições de campo específicas e falham na modelagem dos processos físicos envolvidos na propagação dentro do canal [28]. Estes modelos são conhecidos como “*Modified Exponential Decay Model (MED)*” pois têm o formato $L = X \cdot f^Y \cdot d^Z$ conforme exemplos a seguir:

- Weissberger [28]
 - $L = 1,33 \cdot f^{0,284} \cdot d^{0,588}$ para distâncias (d) entre 14m e 400m (4.1)
 - $L = 0,45 \cdot f^{0,284} \cdot d$ para distâncias (d) entre 0m e 14m (4.2)
- Modelos ITU-R [29]
 - $L = 0,2 \cdot f^{0,3} \cdot d^{0,6}$ (4.3)
- COST 235 [28]
 - $L = 15,6 \cdot f^{-0,009} \cdot d^{0,26}$ [dB] *In-leaf* (4.4)
 - $L = 26,6 \cdot f^{-0,2} \cdot d^{0,5}$ [dB] *Out-of-leaf* (4.5)
- Fitted ITU-R (FITU-R) [28]
 - $L = 0,39 \cdot f^{0,39} \cdot d^{0,25}$ [dB] *In-leaf* (4.6)
 - $L = 0,37 \cdot f^{0,18} \cdot d^{0,59}$ [dB] *Out-of-leaf*, (4.7)

onde L é a atenuação em dB que é adicionada pela vegetação sobre a atenuação do espaço livre (*Free Space Path Loss - FSPL*), d é a distância de profundidade na vegetação em metros, e f é a frequência em GHz para o modelo Weissberger e em MHz para os demais modelos.

A Figura 4.1 mostra alguns destes modelos empíricos e comparações com algumas amostras medidas em campo. As amostras $L_{V,DIRECT}$ correspondem as medidas de atenuação em visada direta entre o transmissor e o receptor, as amostras $L_{V,MAX}$ correspondem as medidas de atenuação no azimute de maior potência recebida e as amostras $L_{V,COMB}$

correspondem as medidas de atenuação quando foram somadas as três maiores potências recebidas nos diferentes azimutes. Estes modelos são conhecidos como “two slopes” pois nos primeiros metros existe a predominância da atenuação da vegetação enquanto no segundo *slope* o efeito do espalhamento diminui a atenuação. No modelo Weissberger a mudança de *slope* ocorre em d igual a 14m conforme equações 4.1 e 4.2.




Fig. 4.1: Modelos empíricos de atenuação em vegetação em 24GHz [8].

4.2.2 MODELOS SEMI-EMPÍRICOS

São modelos simples de aplicar e são formulados para ter a melhor adequação as medições realizadas. Não consideram os processos físicos da propagação na vegetação, mas são baseados no comportamento de absorção e espalhamento do meio. Estes modelos consideram alguns parâmetros de geometria e vegetação como área iluminada, dimensões físicas da floresta e distancia da antena. Seguem dois modelos semi-empíricos [28][46]:

- Non Zero Gradient (NZG) Model

$$\circ L = R_{\infty} \cdot d + k \cdot \left(1 - \exp\left(\frac{(R_0 - R_{\infty}) \cdot d}{k}\right) \right)$$

- L é a atenuação adicionada ao FSPL, R_0 e R_{∞} é a atenuação inicial e final em dB/m, respectivamente, d é a distância de profundidade na vegetação em metros, e k é um *offset* de atenuação em dB.

- Dual Gradient (DG) Model

$$\circ L = \frac{R_{\infty}}{f^a \cdot W^b} \cdot d + \frac{k}{W^c} \cdot \left(1 - \exp\left(\frac{(R_0 - R_{\infty}) \cdot W^c \cdot d}{k}\right) \right)$$

- a , b , c , k , R_0 e R_∞ são parâmetros que dependem da vegetação, f é a frequência em GHz e W é a área iluminada de acordo com a Figura 4.2.

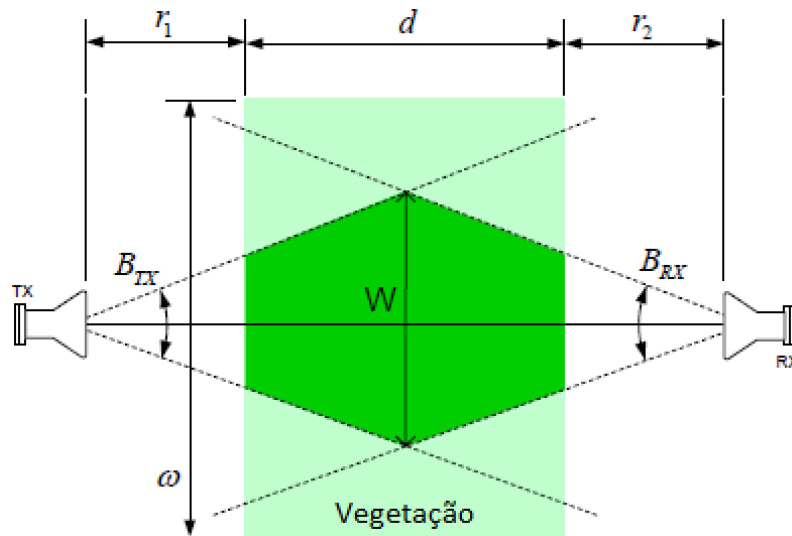


Fig. 4.2: Geometria do cenário no modelo DG [28].

4.2.3 MODELOS ANALÍTICOS

Em contraste com os modelos anteriores, modelos analíticos consideram o processo físico envolvido na propagação das ondas de rádio através da vegetação. No entanto, estes modelos usualmente requerem o uso de métodos de análise numérica para fornecer soluções para a formulação analítica. Seguem alguns modelos analíticos [28]:

- Geometrical and Uniform Theories of Diffraction (GTD/UTD)
 - Modelo baseado em *ray-tracing*
 - Para frequências altas (comprimento de onda comparável com o tamanho dos espalhadores) a vegetação é modelada em camadas heterogêneas conforme Figura 4.3 e para baixas frequências a vegetação é modelada em camadas homogêneas conforme Figura 4.4.

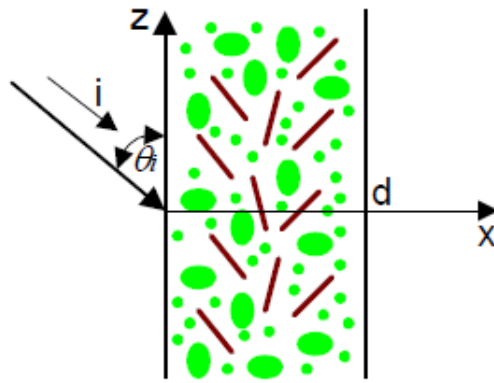


Fig. 4.3: Camadas heterogêneas do modelo GTD/UTD [28].

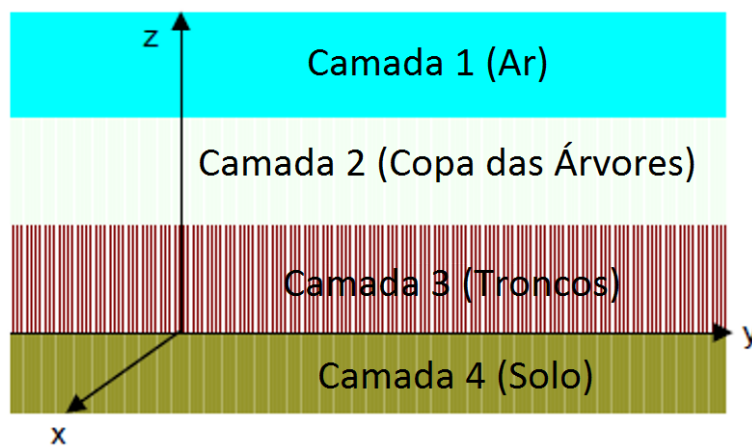


Fig. 4.4: Quatro camadas homogêneas do modelo GTD/UTD [28].

- Radiative Energy Transfer (RET)
 - RET fornece um modelo mais preciso e efetivo da atenuação na vegetação e do espalhamento que pode ser aplicado em uma variedade de geometrias de propagação para frequências acima de 1GHz. Requer a resolução de um conjunto de equações mais complexas do que os modelos empíricos.
 - Vegetação modelada como um meio homogêneo estatisticamente aleatório de espalhadores dS caracterizados pela absorção por unidade de volume σ_a , o espalhador por unidade de volume σ_s , e a função de espalhamento do meio $p = (\hat{s}, \hat{s}')$ conforme Figura 4.5.

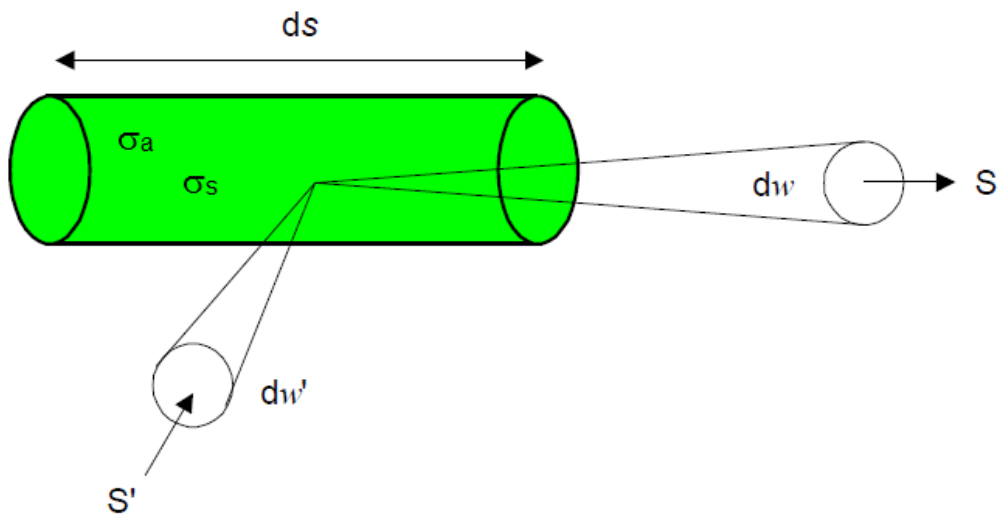


Fig. 4.5: Espalhamento de um meio randômico homogêneo de espalhadores [28].

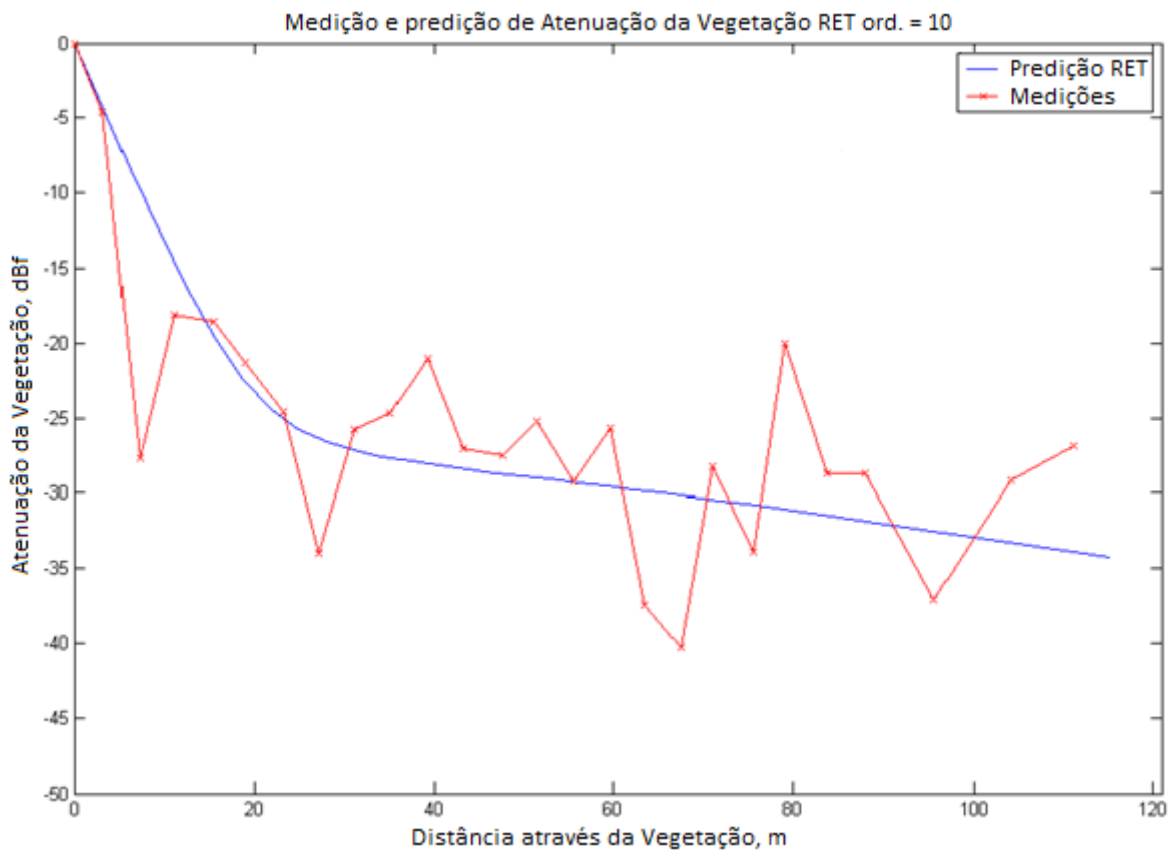


Fig. 4.6: Comparação entre medições e modelo RET em 11GHz [28].

A Figura 4.6 mostra uma comparação entre o modelo RET e medições de campo realizadas em 11GHz em um cenário formado por uma fileira de árvores [28].

- Discrete Radiative Energy Transfer (dRET)
 - Divide a vegetação em células cúbicas sem sobreposição as quais possuem características de propagação individuais conforme Figura 4.7.

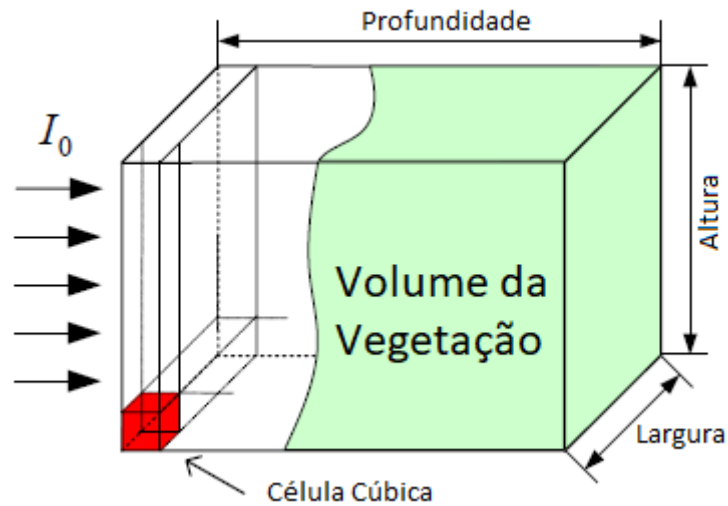


Fig. 4.7: Volume de vegetação dividido em células cúbicas no modelo dRET [28].

A Figura 4.8 apresenta um comparativo entre modelos empíricos, semi-empíricos e analíticos na frequência de 2,5GHz em uma plantação de palmeiras [30].

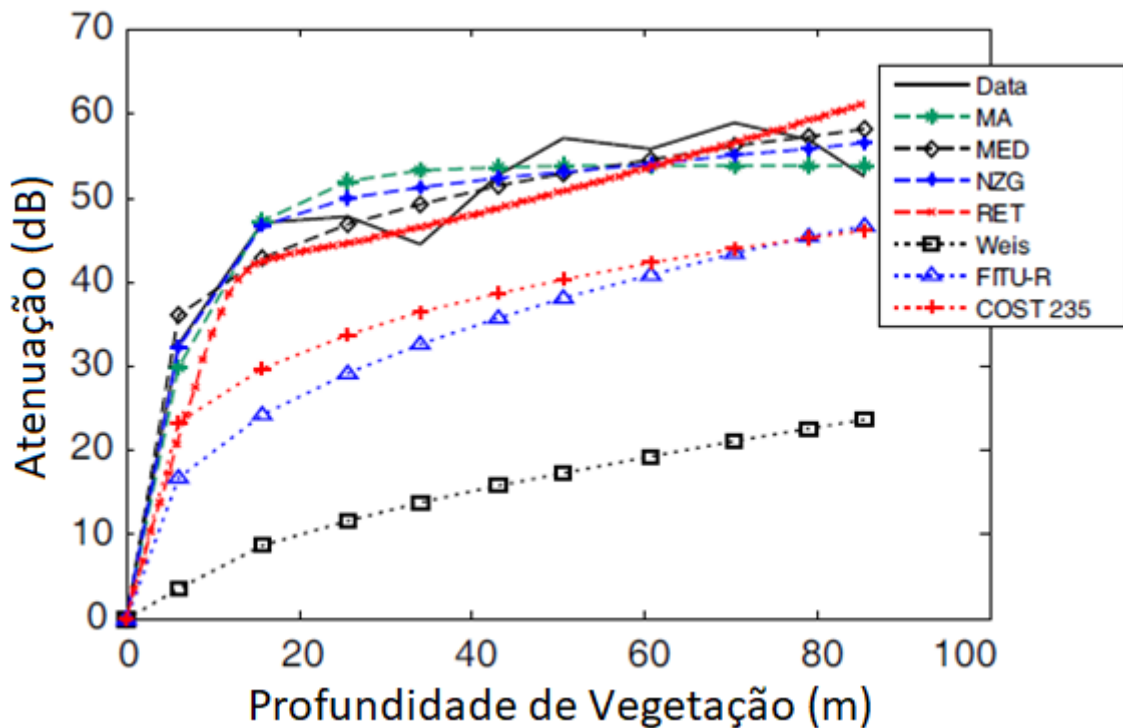


Fig. 4.8: Comparativo de vários dos modelos em 2,5GHz em uma plantação de palmeiras [30].

4.3 CONSIDERAÇÕES FINAIS DOS MODELOS DE ATENUAÇÃO EM VEGETAÇÃO

Foram analisados os principais modelos que explicam a atenuação de sinais propagados em ambiente de vegetação. Nesta tese serão propostos novos modelos empíricos e analíticos que podem complementar estes existentes e que trazem vantagens em termos de

praticidade. Esta praticidade vem do fato de se considerar valores de densidade de vegetação em vez de distância de profundidade de vegetação. Esta densidade é obtida em função de valores de pixel RGB de uma imagem de satélite do cenário da vegetação. Uma alternativa a uma imagem de satélite RGB pode ser a utilização de uma imagem de satélite em infravermelho (IV) que pode inclusive caracterizar com mais detalhes a vegetação. No entanto, nas pesquisas realizadas nesta tese não se teve sucesso em encontrar bases de dados de imagens de satélite em infravermelho nas áreas específicas em que as medições de campo disponíveis foram coletadas.

5 CAMPANHA DE MEDIÇÕES DE CAMPO

5.1 CENÁRIO DE MEDIÇÕES

As campanhas de medições foram realizadas em dois cenários distintos de vegetação do Brasil: na cidade de Manaus no estado do Amazonas com vegetação típica da região norte do Brasil e na cidade de Belo Horizonte no estado de Minas Gerais na região sudeste do Brasil.

A primeira campanha de medições foi realizada em 24 GHz em uma área suburbana de Manaus, no campus da faculdade FUCAPI (Fundação Centro de Análise, Pesquisa e Inovação Tecnológica), no fim do período de chuvas em meados de abril quando todas as árvores estavam com muitas folhas. O cenário é composto de espaços abertos, prédios e forte presença de vegetação com diferentes tipos de árvores sendo algumas destas árvores praticamente exclusivas da região amazônica enquanto outras podem ser encontradas em diferentes regiões do mundo. A altura média das árvores nesta área do cenário de medições é de 9 metros e o diâmetro da copa das árvores varia entre 3 e 13 metros com tamanho estimado das folhas de 15 cm [8]. A Figura 5.1 extraída do *Google Earth* ilustra este cenário.

Os pontos de medição foram separados em 2 grupos. No grupo 1 estão agrupados do ponto 1 ao ponto 9 e no grupo 2 estão agrupados do ponto 10 ao ponto 12 conforme Figura 5.1. Os pontos do grupo 1 foram obtidos do conjunto de medições realizadas em [8] e os pontos do grupo 2 foram obtidos do conjunto de medições realizadas em [6]. O grupo 1 será utilizado para obtenção da distribuição *priori* de atenuação na vegetação que será usado no teorema de Bayes enquanto o grupo 2 será utilizado para obter a distribuição *sampling* de atenuação na vegetação.

Na Figura 5.2 são apresentados mais detalhes da geometria espacial das medições de todos os pontos medidos em [8] e que foram alocados no grupo 1. A numeração dos pontos da Figura 5.2 foi alterada para permitir uma melhor análise conjunta com os demais pontos obtidos em [6] e que formaram o grupo 2. A sequência final de ordenação utilizada está apresentada na Figura 5.1.



Fig. 5.1: Vista aérea 3D do cenário de vegetação: TX e posições medidas dos grupos 1 e 2.




Fig. 5.2: Vista aérea do cenário de vegetação, posições medidas e geometria considerada [8] no grupo 1.

Na Figura 5.3 são apresentados mais detalhes das medições de todos os pontos medidos em [6] e que foram usados para selecionar os 4 pontos que formaram o grupo 2. Apenas os pontos que estavam inseridos dentro de ambiente de vegetação foram considerados.

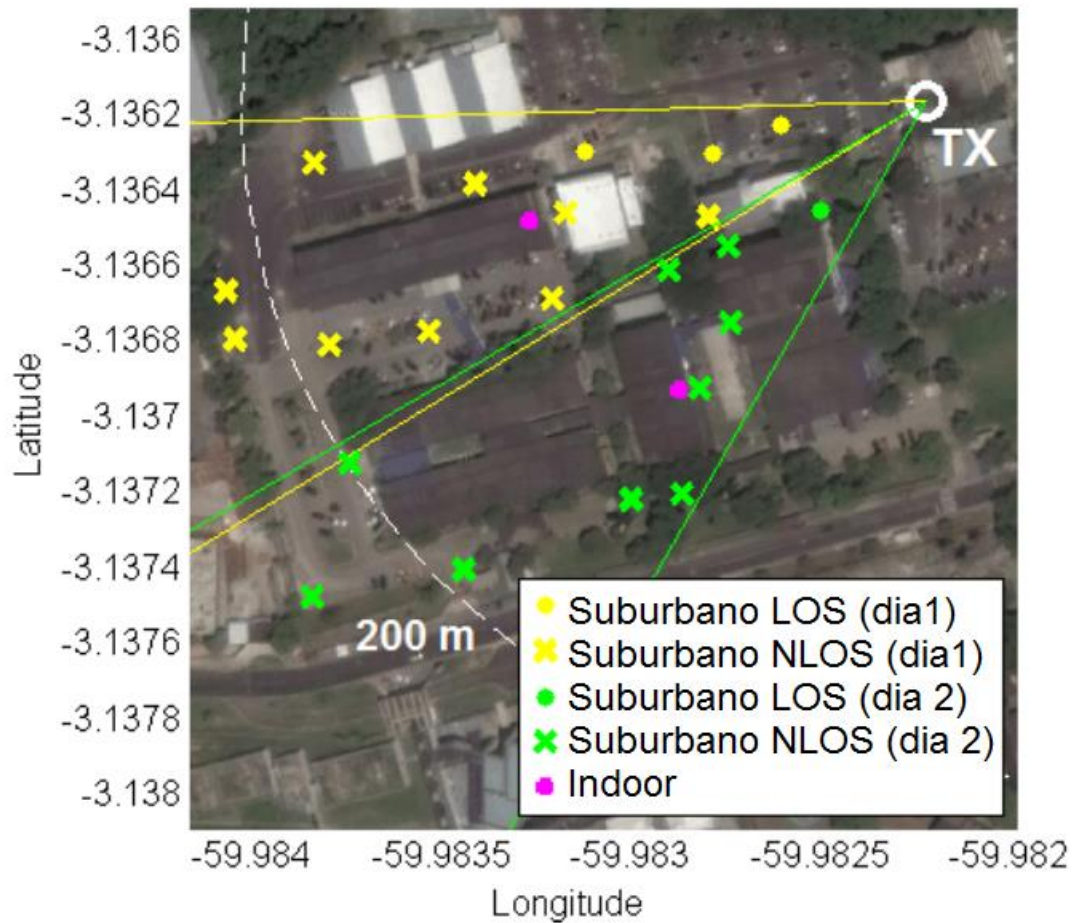


Fig. 5.3: Vista aérea do cenário de vegetação e posições medidas [6] no grupo 2.

A segunda campanha de medições foi realizada em 18 GHz em uma área suburbana de Belo Horizonte, no campus do Centro Federal de Educação Tecnológica de Minas Gerais (CEFET/MG) em novembro de 2016. O cenário é composto de alguns prédios e forte presença de vegetação com diferentes tipos de árvores conforme Figura 5.4 em 3D e a Figura 5.5 em 2D ambas extraídas do *Google Earth*.



Fig. 5.4. Vista aérea 3D do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição



Fig. 5.5. Vista 2D do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição

5.2 CONFIGURAÇÃO DE MEDIÇÕES E PROCEDIMENTOS

As medições no cenário de Belo Horizonte foram realizadas com a antena TX de transmissão de onda contínua (CW) montada a 7 metros de altura e a antena de RX usou um pedestal rotativo a 1,75 metros de altura em cinco diferentes pontos conforme Figura 5.4 e Figura 5.5. Ambos os lados, TX e RX, usaram antenas corneta com ângulo de meia potência (HPBW) de 16°. No ponto RX de número 1 as medições foram realizadas girando todo o azimute da antena, de 0° à 360°, em passos de 10° enquanto a elevação variou de -10 à +10 em passos de 10 graus. Nos demais pontos de RX foi realizada apenas uma medição por ponto com a antena alinhada em direção à antena TX de forma a se obter a máxima potência recebida.

As medições no cenário de Manaus foram realizadas usando um gerador de onda contínua (CW) em 24 GHz e antenas do tipo corneta com 22 dBi de ganho e 25 graus de ângulo de meia potência (HPBW) tanto no lado do transmissor (TX) como no lado do receptor (RX). A antena de TX foi instalada na cobertura de um prédio a 15 metros de altura, transmitindo o sinal de forma a cobrir a área de vegetação densa selecionada. A antena RX foi instalada em um suporte com motor rotativo a uma altura de 1,75 metros do chão. Detalhes adicionais sobre os equipamentos de medição e a configuração do cenário de medição pode ser obtido em [6] e [8]. Um total de 11 enlaces de rádio TX-RX obstruídos por vegetação foram estudados com distâncias (d_p) variando entre 45 e 95 metros e com um comprimento médio de enlace em visada direta RX-TX através da vegetação (d_v) de aproximadamente 10 metros como pode ser visto com detalhes na Figura 5.2. No detalhe na parte de baixo e a esquerda na Figura 5.2 mostra uma diagramação das distâncias d_p e d_v consideradas nos enlaces. Áreas típicas de vegetação dentro de cidades podem apresentar facilmente profundidade de vegetação variando na mesma ordem de grandeza que a apresentada neste cenário de medições [8].

Em cada um dos 11 pontos medidos o azimute da antena de RX variou de 0 a 360 graus enquanto o ângulo de elevação variou de +10 a +30 graus. Os passos angulares de azimute e elevação foram de 9 graus e 10 graus respectivamente resultando em um total de 120 amostras gravadas de potência diretiva para cada um dos 11 pontos medidos. Este procedimento garante a correta amostragem nas medições visto que esta resolução é menor do que a metade do ângulo de meia potência tanto na variação do azimute quanto na elevação [8].

Analisando de acordo com os modelos empíricos conhecidos como “*two slopes*”, todos os pontos de medições dos cenários de Manaus e Belo Horizonte estão posicionados no segundo *slope*. Todos os pontos estão em uma distância de profundidade de vegetação em que

a quantidade de componentes de espalhamento é dominante no efeito de propagação diminuindo a atenuação por metro provocada pela vegetação.

5.3 RESULTADOS DAS MEDIÇÕES

A Figura 5.6 apresenta a visão aérea por satélite da área de medições do grupo 1 mostrando o ângulo de chegada (*angle-of-arrival* (AoA)) para as potências de pico ou lóbulos detectados na posição de medições de número 3. O mapa de calor no lado esquerdo da Figura 5.7 ilustra as potências direcionais medidas no mesmo ponto de número 3 para diferentes valores de elevação e azimute. Tanto na Figura 5.6 quanto na Figura 5.7 as linhas tracejadas em amarelo assinalam a referência da direção azimutal entre TX e RX [8]. A Figura 5.6 foi extraída do GoogleEarth e a data da imagem de satélite utilizada deve ser configurada para 26/03/2015 na linha do tempo de imagens do GoogleEarth. Caso sejam utilizadas imagens de outra data no GoogleEarth, será necessário fazer ajustes nas coordenadas de latitude e longitude dos pontos de medição.

As linhas verdes tracejadas na Figura 5.6 representam os ângulos de chegada (AoA) das componentes espalhadas pelo *clutter* de vegetação. As linhas vermelhas tracejadas na representam os ângulos de chegada das componentes refletidas nas paredes dos prédios adjacentes. Em [8] podem ser encontradas figuras similares à Figura 5.6 com as componentes correspondentes aos outros dez pontos medidos. Estas componentes de AoA mostram que os níveis de potência espalhados pela vegetação são comparáveis ao nível de potência das componentes refletidas nas paredes. O AoA da componente mais forte indicada pelo símbolo X em escala maior no mapa de calor em geral não corresponde à direção de visada direta TX-RX indicada pela linha tracejada em amarelo no mapa de calor da Figura 5.6 e na Figura 5.7.

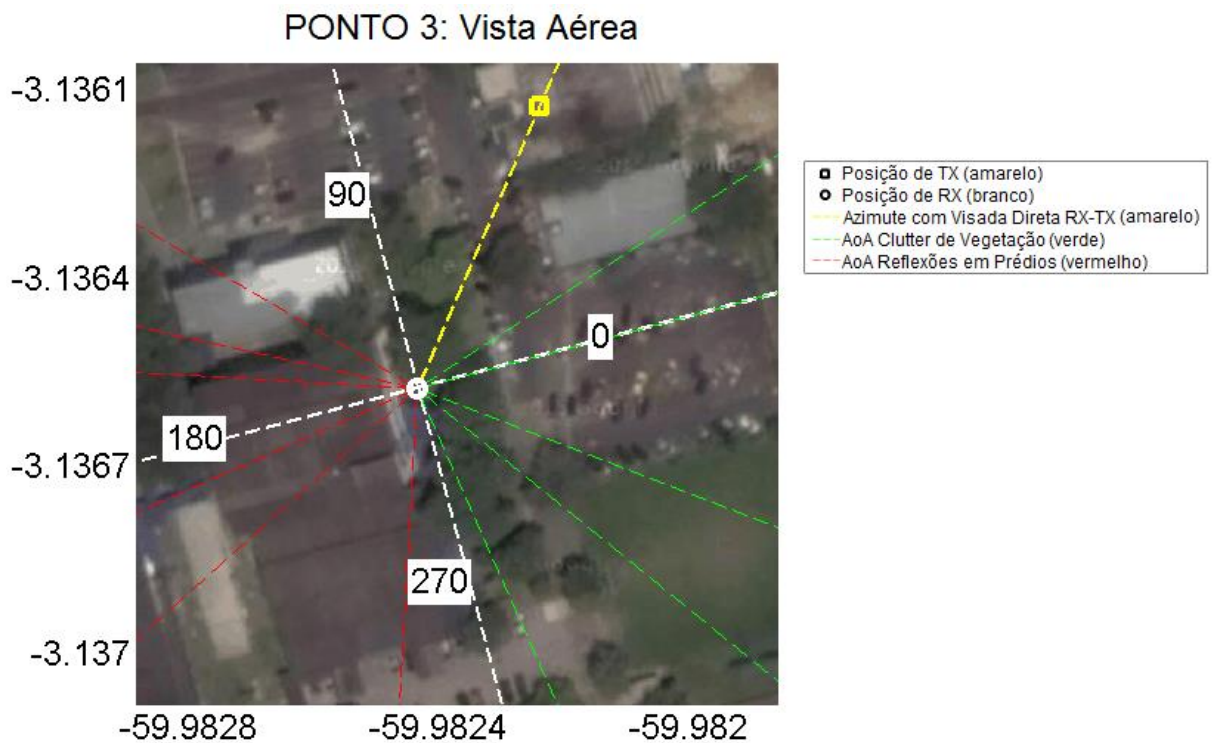


Fig. 5.6: Referências de azimute, AoA das componentes de multipercurso devido a vegetação e reflexões em prédios no ponto 3 [8].

O diagrama polar na Figura 5.7 apresenta a potência recebida para os três ângulos de elevação medidos (10, 20 e 30 graus) no ponto de medições de número 3. De forma a garantir que a medida de potência recebida corresponda a um sinal que sofreu o efeito de atenuação na vegetação, apenas os azimutes de propagação não impactados pelas reflexões nos prédios foram analisados e para estes azimutes foi aplicado a metodologia de estimação de atenuação baseado em pixels.

A Figura 5.8 ilustra na região contornada em amarelo do lado direito os valores de azimutes considerados para o ponto 3, os quais não foram impactados pelas reflexões em prédios. Pode-se observar que o azimute com maior potência recebida não é igual ao azimute do enlace de visada direta com a antena transmissora TX o que pode ser explicado pelo efeito de espalhamento do sinal devido à vegetação.

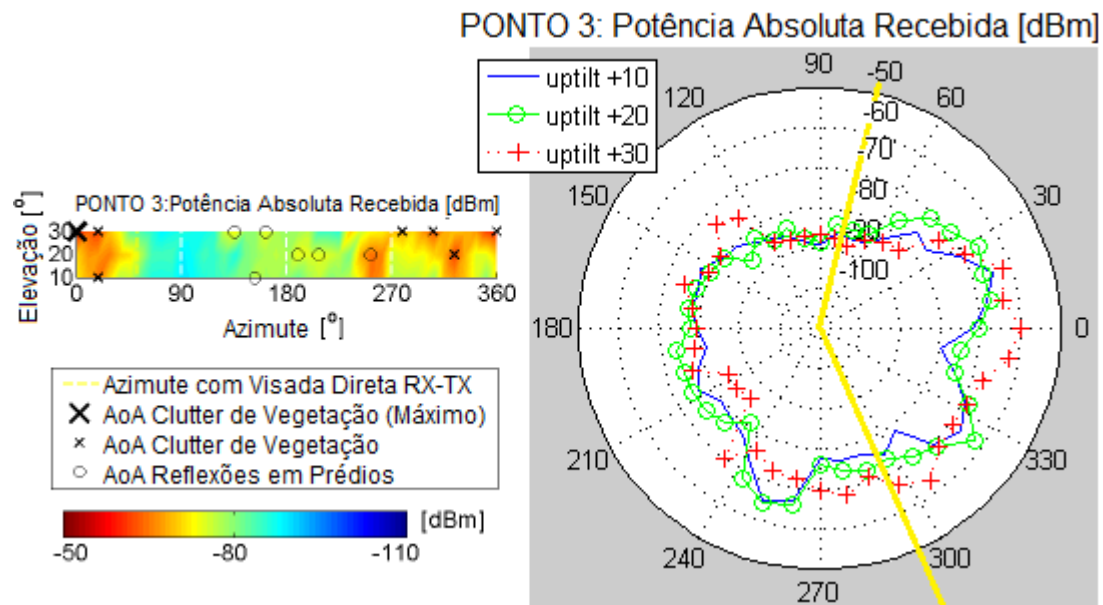


Fig. 5.7: Resultado de medições no ponto 3: valores de potência direcional absoluta recebida para cada elevação (mapa de calor e diagrama polar) [8].

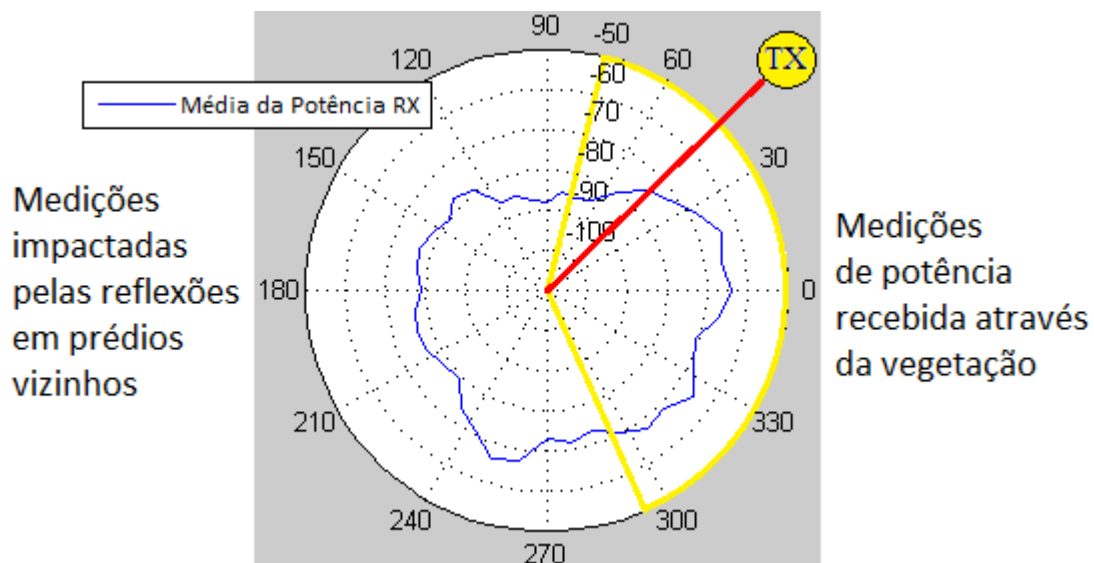


Fig. 5.8: Resultado de medições no ponto 3: valor médio de potência das três elevações medidas (+10, +20, +30).

5.4 ANÁLISE DAS MEDIÇÕES

A Tabela 5.1 apresenta alguns parâmetros extraídos do cenário de propagação em vegetação nos 7 pontos do grupo 1 e a média dos valores de potência e atenuação medidos para cada um dos pontos analisados. Foram considerados no cálculo destas médias apenas os azimutes impactados pela vegetação e que não foram impactados pelas reflexões nos prédios.

Os valores absolutos medidos para todos os azimutes entre 0 graus e 360 graus em passos de 9 graus e três diferentes elevações podem ser encontrados em [8]. Na Tabela 5.1 o valor #tr apresenta o número de copas de árvores obstruindo a linha de visada. L_v apresenta a atenuação devido a vegetação para o caso do AoA recebendo a componente P_{RX} de potência direta TX-RX calculada conforme as equações 5.1 e 5.2. A potência P_{RX} considerada foi a média das potências recebidas para os 3 valores de elevação medidos (+10, +20 e +30 graus). A tabela 5.1 apresenta a média dos valores de L_v analisados para cada um dos 7 pontos.

$$L_v = EIRP - FSPL + G_{RX} + G_{RF} - P_{RX} \text{ [dB]} \quad (5.1)$$

$$FSPL = 20 \log [f \text{ (MHz)}] + 20 \log [d \text{ (Km)}] + 32,44 \quad (5.2)$$

O valor de EIRP (Potência Isotrópica Efetivamente Radiada) na Equação 5.1 foi de +34dBm e G_{RF} é uma constante de 5 dB que corresponde a todos os ganhos extras de RF combinados que foram introduzidos no lado do RX pelo cabo, conectores e pré-amplificador de baixo ruído. FSPL é a perda no espaço livre.

Tabela 5.1: Sumário dos parâmetros de cada ponto analisado no cenário e respectivos valores medidos

#	d_v [m]	#tr	FSPL [dB]	P_{RX} Médio [dBm]	L_v Médio [dB]
3	7.20	1	94.96	-70,0	36,08
4	5.14	1	96.35	-70,3	34,93
5	3.60	1	97.96	-75,9	38,95
6	6.17	2	98.67	-78,3	40,67
7	9.26	3	99.38	-83,6	45,26
8	9.77	3	99.83	-89,6	50,74
9	9.98	2	99.81	-88,3	49,51
10	8.23	2	99.67	-88,1	49,39

5.5 CONSIDERAÇÕES FINAIS DA CAMPANHA DE MEDIÇÕES

Esta campanha de medições forneceu os dados necessários de componentes de multi-percurso e de valores de atenuação gerados pela folhagem da vegetação. Após um processo de filtragem para se obter medições unicamente impactadas pela vegetação, as medições estão prontas para serem utilizadas pelo método de estimação de atenuação em vegetação desenvolvido nesta tese.

6 PROCESSAMENTO DA IMAGEM DE VEGETAÇÃO

Na metodologia desenvolvida neste estudo a atenuação na vegetação é estimada utilizando a densidade de vegetação baseada em valores de pixel extraídos de imagem via satélite da área de propagação na vegetação. A densidade de vegetação é usada como um estimador equivalente (*proxy estimator*) estatístico para determinar a atenuação na vegetação. Nesta metodologia não é necessário a utilização da distância da profundidade de vegetação e este modelo é complementar ao modelo físico do fenômeno de propagação baseado em distância da profundidade de vegetação.

6.1 FILTRAGEM DE PIXELS DA VEGETAÇÃO

Para automatizar a captura das imagens de satélite foi usada a API (*Application programming interface*) denominada “Google Static Maps API”. As imagens de satélite de Manaus dos grupos 1 e 2 foram capturadas na data de 26/03/2015. A imagem de satélite de Belo Horizonte foi capturada no dia 28/08/2017.

Foram aplicadas duas rotinas de filtragem de pixels na imagem digital de satélite. A primeira para excluir os pixels de edificações e a segunda para manter apenas os pixels de vegetação. Em ambas as filtrações foi utilizado a toolbox Matlab de processamento de imagem tendo sido utilizado o algoritmo L^*a^*b para segmentação em um espaço amostral de cores (*colorspace*) conforme [31][32][47]. O L^*a^*b consiste de uma camada de brilho ou luminosidade ' L^* ', uma camada de cromaticidade ' a^* ' indicando a cor em uma escala de verde-vermelho e uma camada de cromaticidade ' b^* ' indicando a cor em uma escala de azul-amarelo [33]. O resultado está apresentado na Figuras 6.1 para a imagem utilizada no grupo de pontos de medições 1 e na Figura 6.2 para a imagem do grupo 2.

Na rotina de filtragem para manter apenas os pixels de vegetação o espaço de cores foi configurado com um espaço de cores (*colorspace*) com amostras de pixels extraídos da própria imagem em 2 grupos, um de vegetação e outro de não vegetação. O algoritmo L^*a^*b quantifica as diferenças no valor dos pixels entre estes dois grupos ou áreas amostrais de pixels e classifica todos os pixels da imagem de acordo com estes 2 grupos. As amostras de pixels de vegetação são configuradas no espaço amostral de cores do algoritmo colocando as coordenadas de pontos que limitam uma área qualquer fechada que possui apenas pixels de

vegetação. O mesmo processo é feito para uma área que possui apenas pixels que não são de vegetação. O algoritmo calcula a média dos valores 'a*' e 'b*' dos pixels para cada uma das áreas, e estas médias servem como marcadores no espaço 'a*b*' para identificar a área de pixels. A classificação de cada pixel na imagem original é feita calculando-se a distância euclidiana no espaço 'a*b*' entre este pixel e cada um dos marcadores das áreas de pixel. A menor distância euclidiana entre o valor do pixel e os marcadores das áreas de pixel determina qual a classificação do pixel. Podem ser colocados mais grupos no algoritmo L*a*b, mas para o propósito desta metodologia apenas 2 grupos foram necessários. Processo semelhante foi realizado na primeira rotina que excluiu os pixels de edificações.

Após a classificação dos pixels de vegetação pode-se gerar a imagem formada apenas pelos pixels de vegetação. O algoritmo altera os pixels não classificados como vegetação para o valor RGB (0,0,0), ou seja, as componentes RED, GREEN e BLUE são alteradas para zero que equivale a cor preto. De forma a permitir uma melhor visualização os pixels não classificados como vegetação que estavam com valor RGB (0,0,0) foram alterados para RGB (255,255,255) que corresponde a cor branco conforme a Figura 6.1. Os pixels de vegetação apresentados na Figura 6.1 e na Figura 6.2 possuem a mesma cor que os respectivos pixels na Figura 5.3, mas devido a coloração escura da vegetação a mesma aparenta estar em tons de cinza.

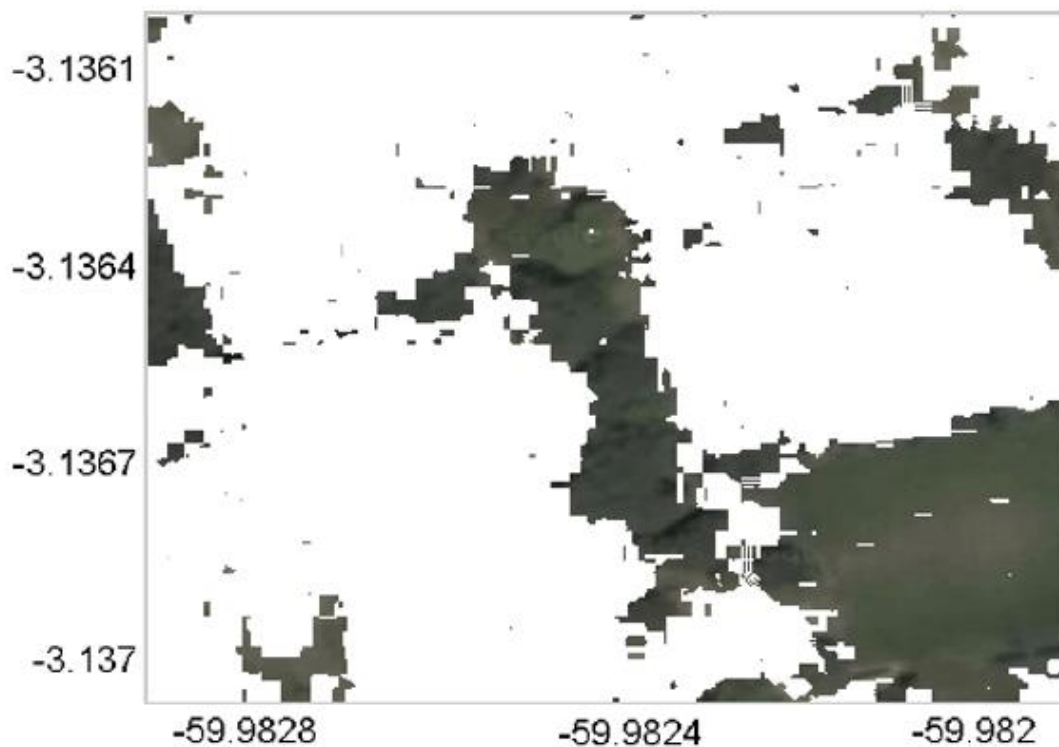


Fig. 6.1: Imagem de satélite após filtro para selecionar os pixels de vegetação (grupo 1 de Manaus).




Fig. 6.2: Imagem de satélite após filtro para selecionar os pixels de vegetação (grupo 2 de Manaus) e retângulo verde mostrando pixels contíguos ao ponto de medição 12.

6.2 ANÁLISE DE PIXELS

Após a filtragem dos pixels de vegetação, foi desenvolvido um algoritmo para extrair da imagem a área mais provável de propagação do sinal radiado pela antena de TX e recebido pela antena de RX. Um exemplo desta área mais provável de propagação é mostrado em azul na Figura 6.3 para imagem do grupo 1 de pontos de medição e na área tracejada de amarelo na Figura 6.4 para imagem do grupo 2. A imagem de satélite original foi utilizada em vez da imagem das Figuras 6.1 e 6.2 para melhor entendimento espacial da área de propagação selecionada. Esta área é formada por um polígono cujos vértices são os pontos das antenas de TX e RX, e dos pontos de intersecção A e B mostrados nas Figuras 6.3 e 6.4. Os pontos A e B indicam a intersecção dos ângulos de meia potência das antenas de TX e RX, ou de acordo com a Figura 6.3, a intersecção das retas de cor vermelha e de cor azul. As retas de cor vermelho e azul representam o ângulo de meia potência de 25 graus de abertura (HPBW) das antenas de TX e RX respectivamente. Esta área azul da Figura 6.3 representa um filtro da região mais provável de propagação do sinal e este filtro será aplicado na Figura 6.1 de forma a se obter apenas os pixels de vegetação que influenciarão na propagação. Para automatizar o

desenho de retas e áreas sobre as imagens de satélite foi usada novamente a API denominada “Google Static Maps API”.




Fig. 6.3: Área azul mostra exemplo de região da imagem de satélite considerada na análise de pixels de vegetação (grupo 1 de Manaus).

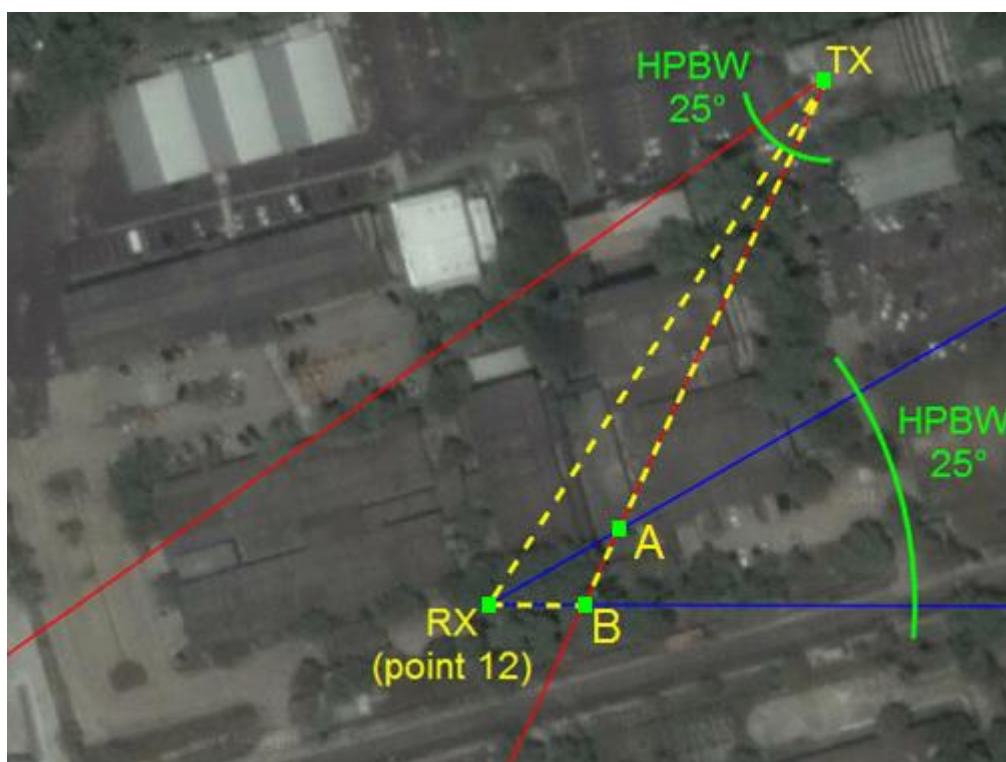


Fig. 6.4: Área azul mostra exemplo de região da imagem de satélite considerada na análise de pixels de vegetação (grupo 2 de Manaus).



Fig. 6.5. Vista do cenário de vegetação em Belo Horizonte: ponto de antena TX e 5 pontos de medição

A seleção desta área de propagação foi feita para cada AoA (azimute) em cada um dos 12 pontos de medição analisados nas imagens dos grupos 1 e 2. As componentes com AoA provenientes da reflexão nos prédios foram eliminadas para não comprometer a análise.

Para cada valor de pixel RGB foi calculado o valor de intensidade de HSI (*Hue Saturation Intensity*) que corresponde à média dos valores de Red, Green e Blue conforme Equação 6.1. Para cada área de propagação extraída da imagem foi calculado o somatório dos valores HSI de todos os pixels. Ao longo do texto será o usado o termo RGB ou HSI para indicar a soma indicada na Equação 6.1.

$$I = (R + G + B) / 3 \quad (6.1)$$

Segue a sequência do procedimento utilizado para filtrar os pixels de vegetação que impactaram na propagação em ambos os cenários de Manaus e Belo Horizonte:

- Marca-se o ponto de transmissão da antena TX e o ponto de medição da antena de RX conforme exemplo da Figura 6.3.
- Determinam-se os azimutes das antenas de TX e RX, os quais podem ser observados no exemplo da Figura 6.3. O azimute da antena de TX manteve-se fixo durante todas as medições enquanto o azimute da antena RX foi variado em passos de 9 graus.

- Desenha-se na imagem as retas de cor vermelha que representam o ângulo de meia potência de 25 graus de abertura (HPBW) da antena de TX, as quais podem ser observadas no exemplo da Figura 6.3. O azimute da antena de TX manteve-se fixo durante todas as medições, logo a área formada pelo ângulo de meia potência da antena TX permaneceu sempre a mesma.
- Desenha-se na imagem as retas de cor azul que representam o ângulo de meia potência de 25 graus de abertura (HPBW) da antena de RX, as quais podem ser observadas no exemplo da Figura 6.3.
- Encontram-se os pontos de intersecção das retas de cor vermelha e azul que indicam os ângulos de meia potência das antenas de TX e RX, respectivamente. No exemplo da Figura 6.3, a intersecção das retas de cor vermelha e de cor azul estão indicados nos pontos A e B.
- Determina-se o polígono formado pelos pontos RX, TX, A e B. Este polígono indica a região mais provável de propagação do sinal radiado pela antena de TX e recebido pela antena de RX. Este polígono é a área de cor azul no exemplo da Figura 6.3. De acordo com o azimute e a posição da antena de RX, este polígono pode ter 3 lados conforme exemplo da Figura 6.3 ou pode ter 4 lados.
- Repetem-se todos os passos anteriores para todos os azimutes medidos na antena de RX. Os azimutes foram medidos em passos de 9 graus, totalizando 40 medições. São encontradas 40 áreas de propagação para cada ponto de medição.
- Elimina-se, manualmente, os azimutes que tenham sido impactos por reflexões em prédios. Os prédios refletem o sinal propagado o que impacta na análise da propagação na vegetação.
- Repetem-se todos os passos anteriores para todos os pontos de RX que são objeto deste estudo. Foram selecionados 12 pontos dentre os 15 pontos medidos.
- Aplicam-se todos estes filtros de áreas obtidos, conforme exemplificado na área azul da Figura 6.3, na imagem da Figura 6.1. A imagem da Figura 6.1 tem apenas os pixels de vegetação. Como resultado tem-se os pixels de vegetação da área mais provável de propagação do sinal obtido para cada azimute da antena de RX e para cada ponto de medição RX.

- Para cada conjunto de pixels de vegetação obtido da filtragem das áreas do polígono de propagação calcula-se o somatório dos valores HSI (ou RGB) de cada pixel. A equação 6.1 apresenta como calcular o valor HSI de cada pixel.
- Dentro do polígono de propagação apenas os pixels de vegetação contíguos com o ponto de medição são considerados no somatório dos valores HSI (ou RGB) conforme o exemplo mostrado na Figura 6.2. O retângulo verde mostra os pixels contíguos ao ponto de medição 12. A inclusão de pixels não contíguos resultou em uma correlação negativa entre o somatório de pixels e o valor de atenuação na vegetação.
- Como resultado tem-se um valor que identifica o somatório de valores RGB dos pixels contíguos de vegetação dentro das áreas de propagação. Este valor foi calculado para cada azimute da antena de RX e para cada ponto de medição RX.
- Foi necessária a normalização do somatório de pixels de acordo com a área da imagem. A imagem do grupo 1 de Manaus (Figura 6.3) foi utilizada como referência. A imagem utilizada nos pontos de medição do grupo 2 de Manaus (Figura 6.4) tem uma área 3 vezes maior do que a área da imagem utilizada nos pontos de medição do grupo 1 de Manaus. Desta forma o somatório de pixels extraídos da imagem do grupo 2 de Manaus foi multiplicado por 3 possibilitando a análise conjunta dos pontos das duas imagens. Da mesma forma os valores dos somatórios de pixels de RGB do cenário de Belo Horizonte (Figura 6.5) foi multiplicado por 1,8 pois a área desta imagem é 1,8 vezes maior do que a área da imagem de Manaus do grupo 1.

7 METODOLOGIA DE CARACTERIZAÇÃO DA ATENUAÇÃO NA VEGETAÇÃO

7.1 MAPEAMENTO DE PIXELS RGB EM ATENUAÇÃO NA VEGETAÇÃO

A Tabela 7.1 tem o intuito de comparar os valores dos somatórios de RGB de cada ponto com a média de atenuação e com os demais parâmetros do cenário de propagação em vegetação para o grupo 1 de Manaus apresentados anteriormente na Tabela 5.1. Conforme a sequência do procedimento acima, para cada ponto foi calculado um conjunto de somatórios de valores de pixels de vegetação, sendo cada um destes somatórios associado a um azimute analisado. De forma a se ter um valor representativo de RGB para cada ponto foi calculado a média dos somatórios dos valores de RGB para cada azimute o qual é apresentado na coluna “Média da Soma RGB de pixels” da Tabela 7.1. O valor da “Média da Soma RGB de pixels” foi dividido por 10^7 para evitar a instabilidade no cálculo dos momentos estatísticos da UT (transformada da incerteza) que serão utilizados no cálculo das distribuições de atenuação. Esta instabilidade no cálculo vem do fato que quanto maior o momento estatístico utilizado maior é o valor do índice da exponencial utilizada para o cálculo da UT.

Tabela 7.1: Sumário dos parâmetros e valores da soma de RGB de cada ponto do grupo 1 de Manaus

#	Média da Soma RGB de pixels / (10^7)	d_v [m]	#tr	FSPL [dB]	P_{RX} Médio [dBm]	L_v Médio [dB]
3	0,30	7.20	1	94.96	-70,0	36,08
4	0,37	5.14	1	96.35	-70,3	34,93
5	0,55	3.60	1	97.96	-75,9	38,95
6	0,56	6.17	2	98.67	-78,3	40,67
7	0,61	9.26	3	99.38	-83,6	45,26
8	0,67	9.77	3	99.83	-89,6	50,74
9	0,67	9.98	2	99.81	-88,3	49,51
10	0,69	8.23	2	99.67	-88,1	49,39

A Figura 7.1 apresenta a regressão linear relacionando a atenuação na vegetação medida e o somatório de valores de RGB dos pixels da área mais provável de propagação para cada azimute e para todos os 7 pontos analisados no grupo 1 de Manaus. Outras regressões de ordem superior foram utilizadas, mas não mostraram ganhos significativos no valor calculado

da correlação. O valor de correlação calculado entre essas duas variáveis foi de 0,62. A regressão mostrou que 38,71% da variação da atenuação na vegetação (valor R^2) foi devido os valores RGB dos pixels de vegetação. Regressões polinomiais de ordem 4, 5 e 6 apresentaram uma variação da atenuação na vegetação (valor R^2) entre 38,86% e 38,93%. A Figura 7.2 apresenta a correlação para o grupo 2 de Manaus, onde o valor de correlação calculado entre essas duas variáveis foi de 0,56. A regressão mostrou que 31,9% da variação da atenuação na vegetação (valor R^2) foi devido os valores RGB dos pixels de vegetação para o grupo 2. A Figura 7.3 apresenta a correlação para Belo Horizonte, onde o valor de correlação calculado entre essas duas variáveis foi de 0,57. A regressão mostrou que 32,4% da variação da atenuação na vegetação (valor R^2) foi devido os valores RGB dos pixels de vegetação para o cenário de Belo Horizonte.

O coeficiente de determinação valor R^2 indica a quantidade de variação de uma variável y que pode ser explicada pela variável x em uma regressão linear. Quanto maior o valor de R^2 maior a variabilidade que é explicada pela regressão linear [34]. Os marcadores circulares em amarelo nas Figuras 7.1 a 7.3 mostram a média de atenuação e do somatório de pixels RGB para cada um dos 12 pontos medidos.




Fig. 7.1: Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para o grupo 1 de Manaus




Fig. 7.2: Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para o grupo 2 de Manaus

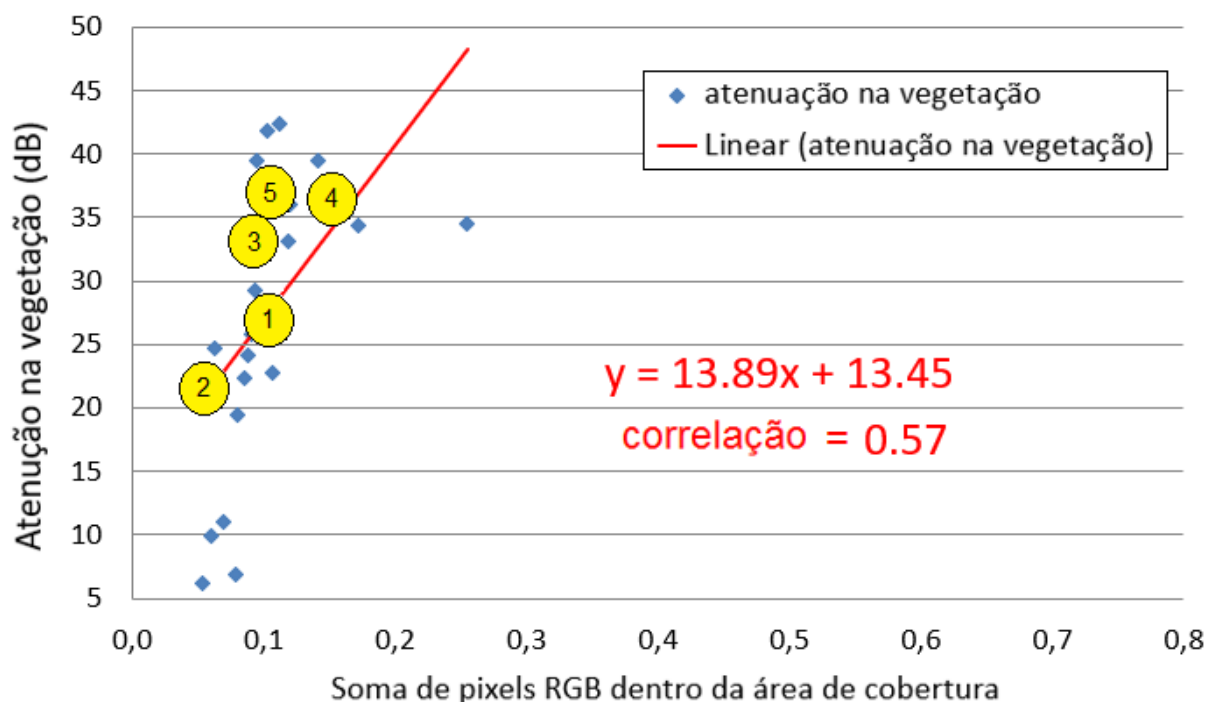


Fig. 7.3: Regressão linear das medições de atenuação na vegetação em função do somatório dos valores de RGB dos pixels da vegetação para Belo Horizonte

Cada ponto no gráfico das Figuras 7.1 a 7.3 representa a associação entre o somatório do valor de pixels de vegetação para cada azimuth de cada ponto medido e a respectiva atenuação na vegetação. Para cada azimuth foi calculado o somatório dos valores RGB de

pixels de vegetação. Este somatório está normalizado no gráfico pois esta normalização será necessária para a aplicação da UT conforme será explicado adiante. A atenuação na vegetação apresentada nestes gráficos das Figuras 7.1 a 7.3 foi obtida utilizando a Equação 7.1, sendo esta é a mesma equação explicada e apresentada na Equação 5.1.

$$L_v = \text{EIRP} - \text{FSPL} + G_{\text{RX}} + G_{\text{RF}} - P_{\text{RX}} [\text{dB}] \quad (7.1)$$

Esta atenuação foi obtida considerando a potência recebida em dBm como a média das potências recebidas nas 3 elevações medidas (10, 20 e 30 graus). O mapeamento entre os valores de pixel de vegetação e a sua atenuação correlacionada da Figura 7.1 para o grupo 1 de pontos de medição foi utilizado para obter a distribuição *priori* de atenuação. O mapeamento entre os valores de pixel de vegetação e a sua atenuação correlacionada da Figura 7.2 para o grupo 2 de pontos de medição foi utilizado para obter a distribuição amostral (*sampling*) de atenuação. Estas distribuições *priori* e amostral (*sampling*) serão utilizadas no teorema de Bayes da inferência para se calcular a distribuição *posteriori* da atenuação na vegetação.

7.2 TRANSFORMADA DA INCERTEZA APLICADA AO TEOREMA DE BAYES

O método usado para calcular a inferência de Bayes em conjunto com a Transformada da Incerteza (UT) primeiramente calcula os pontos sigma e os pesos da distribuição *priori* de pixels de RGB de vegetação da imagem do grupo 1. Estes pontos sigma de RGB são mapeados na função de correlação da Figura 7.1 para se obter os pontos sigma e os pesos da distribuição *priori* de atenuação do grupo 1. Com este procedimento calcula-se a distribuição *priori* UT de atenuação pelo mapeamento da distribuição *priori* UT de pixels RGB de vegetação. Os pontos sigma da distribuição UT *priori* de RGB são usados como valores de entrada da função da regressão linear de forma a calcular os pontos sigma da UT *priori* de atenuação. Os pesos da distribuição UT *priori* de RGB são os mesmos pesos da distribuição UT *priori* de atenuação. O mesmo procedimento é utilizado para se obter os pontos sigma e pesos de atenuação da *sampling* de atenuação pelo mapeamento na função de correlação da Figura 7.2 do grupo 2 de Manaus. As distribuições UT com 6 pontos sigma da *priori* do somatório de pixels RGB de vegetação e da atenuação correlacionada estão mostradas na Figura 7.4. De forma análoga, as distribuições UT *sampling* do somatório de pixels RGB de vegetação e da atenuação correlacionada estão mostradas na Figura 7.5.

Neste procedimento foi necessário normalizar os valores do somatório de pixels RGB de vegetação antes de calcular os momentos da distribuição necessários para aplicar a UT. Ao se normalizar estes valores, mantendo o máximo valor próximo de 1, reduziu-se o esforço computacional para se calcular os momentos de ordem superior o qual aumenta exponencialmente com o número da ordem do momento e evitou-se instabilidade numérica no cálculo dos resultados estatísticos obtidos.

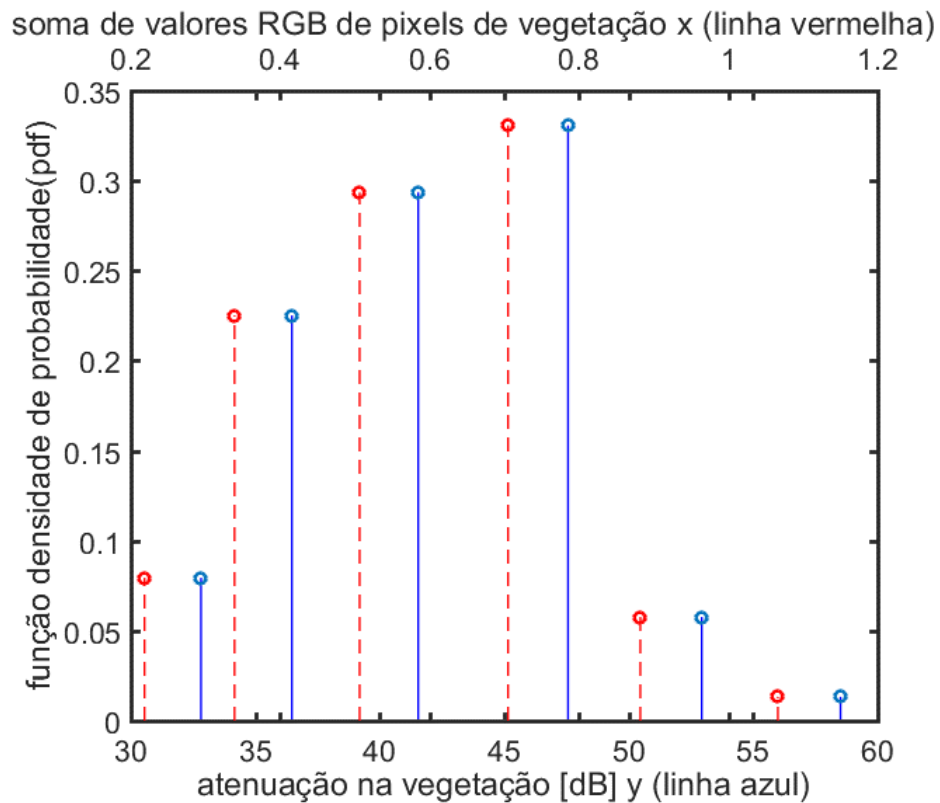


Fig. 7.4: Distribuição UT dos valores RGB de pixels e de atenuação da vegetação (grupo 1 de Manaus)




Fig. 7.5: Distribuição UT dos valores RGB de pixels e de atenuação da vegetação (grupo 2 de Manaus)

A distribuição *posteriori* de Bayes $p(y|x)$ é obtida multiplicando a distribuição *priori* $p(y)$ e a distribuição *sampling* $p(x|y)$ conforme a Equação 7.2, no entanto a multiplicação de distribuições UT com pontos sigma diferentes não está disponível no estado da arte.

$$p(y|x) = \frac{p(x|y)*p(y)}{\int_0^1 p(x|y)*p(y)dy} \quad (7.2)$$

A Figura 7.6 detalha a metodologia desenvolvida neste trabalho para a partir dos pixels RGB de vegetação se obter a distribuição UT de atenuação. No lado esquerdo da Figura 7.6 é apresentada o mapeamento da distribuição UT dos pixels RGB de vegetação através da regressão linear em uma distribuição UT de atenuação. Este processo é executado tanto para o cálculo da *priori* utilizando as medições do grupo 1 de pontos quanto para o cálculo da *sampling* utilizando as medições do grupo 2 de pontos. Ao centro da Figura 7.6 são calculados os “novos pontos sigma comuns” visto que esta condição é necessária para permitir a multiplicação da UT *priori* pela UT *sampling*. As Equações 7.3 e 7.4 detalham a metodologia utilizada para se aplicar as transformadas UT das distribuições *priori* e da *sampling* de atenuação no cálculo da inferência de Bayes. Esta técnica calcula novas distribuições UT da *priori* e da *sampling* as quais terão novos pontos sigma comuns (S_m), diferentes pesos (p_m), mas mantendo os mesmos valores dos momentos estatísticos das

distribuições anteriores. A multiplicação das distribuições UT, conforme mostrado no lado direito da Figura 7.6, será possível porque ambas as distribuições terão os mesmos pontos sigma (S_m). Os pesos destas novas distribuições são calculados de forma que os momentos estatísticos sejam preservados.

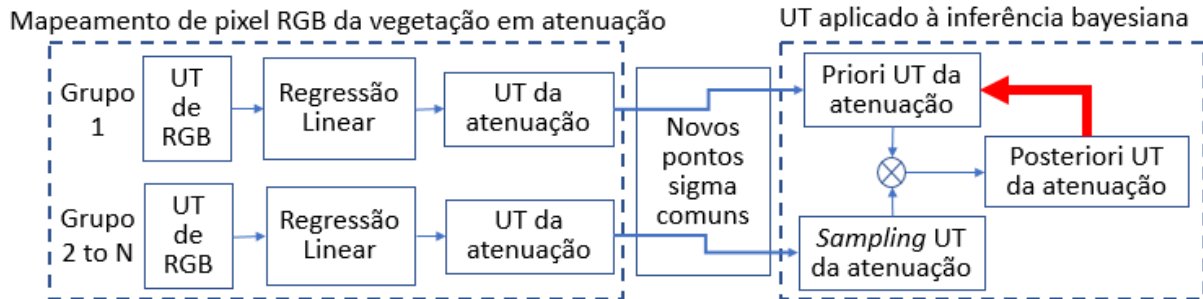


Fig. 7.6: Método de mapeamento de pixels RGB em atenuação e aplicação da UT na inferência bayesiana para obter a atenuação na vegetação.

As Equações 7.3 e 7.4 mostram como as novas distribuições UT da *priori* e da *sampling* se relacionam com os pontos sigma (S_i e S_q) e pesos (p_i e p_q) anteriores. Tanto a equação 7.3 quanto a equação 7.4 podem representar a distribuição *priori* ou a *sampling* visto que este sistema de equações mostra como duas distribuições UT quaisquer com pontos sigma diferentes podem ter seus pontos sigma alterados de forma a permitir a multiplicação entre as distribuições. Como são obtidos pontos sigma (S_m) iguais para ambas as distribuições *priori* e *sampling* então a Equação 7.2 pode ser calculada. Novas medições podem refinar a distribuição *posteriori* ao se calcular novas distribuições UT *sampling* de atenuação e desde que a distribuição *priori* utilizada seja realimentada pela distribuição *posteriori* anterior conforme indicado na seta em vermelho na Figura 7.6.

$$\sum_{i=1}^N p_i * S_i^k = \sum_{m=1}^N p''_m * S_m^k = E\{x_1^k\} \quad (7.3)$$

$$\sum_{q=1}^N p_q * S_q^k = \sum_{m=1}^N p'_m * S_m^k = E\{x_2^k\} \quad (7.4)$$

A Figura 7.7 apresenta a distribuição UT *posteriori* de atenuação na vegetação com 6 pontos sigma após a multiplicação das distribuições *priori* e *sampling*. Esta *posteriori* UT foi calculada utilizando a metodologia apresentada na Figura 7.6 e as medições de pixel RGB e atenuação dos grupos 1 e 2 de pontos. Além do resultado apresentado na Figura 7.6, foram

calculadas diferentes distribuições UT *posteriori*, com 6 ou menos pontos sigma da UT, e o cálculo do valor esperado variou apenas 1 dB. Como pode ser visto na Figura 7.7 a multiplicação direta entre a distribuição *priori* de atenuação e a distribuição *sampling* de atenuação geraria um resultado nulo visto que estas distribuições possuem pontos sigma diferentes. Para se obter a distribuição *posteriori* apresentada na Figura 7.7 foi necessário se executar o alinhamento dos pontos sigma das distribuições *priori* e *sampling* utilizando o método apresentado nas Equações 7.3 e 7.4. Consegue-se perceber visualmente na Figura 7.7 uma maior influência da distribuição *sampling* do que da distribuição *priori* no resultado da distribuição *posteriori*, por exemplo, o ponto sigma de maior amplitude da *posteriori* está alinhado com o ponto sigma de maior amplitude da *sampling*. Isto pode ser explicado pela maior precisão da *sampling* em relação *priori* a conforme definição do teorema de Bayes apresentado no capítulo 3 desta tese. A *posteriori* apresentou uma precisão maior do que a *priori* e a *sampling*.

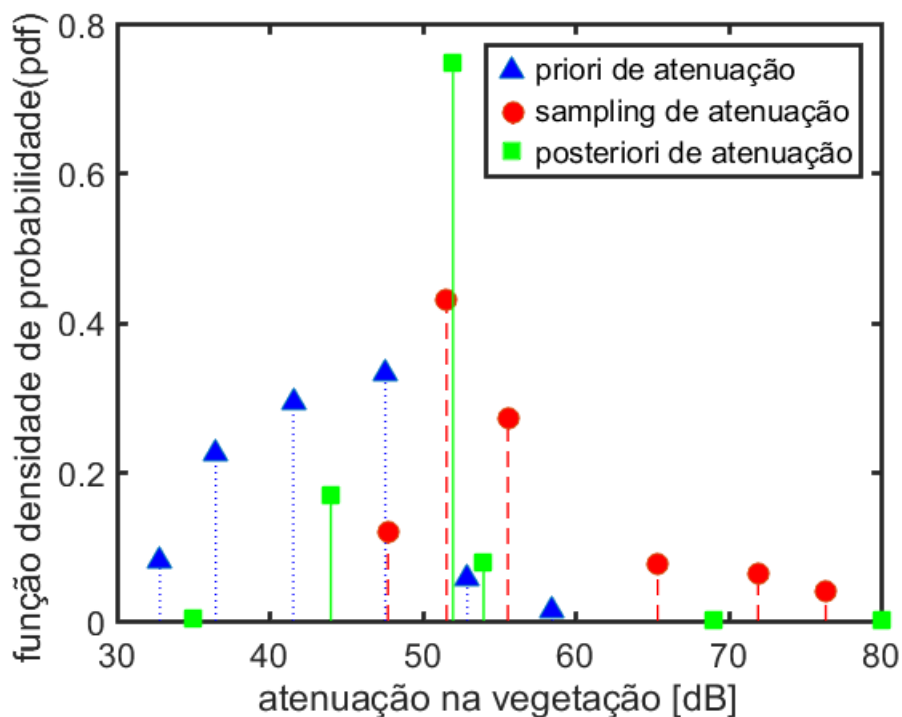


Fig. 7.7: Distribuição UT de atenuação da vegetação em Manaus: *posteriori*, *priori* e *sampling*

Este resultado mostra como esta metodologia pode inferir a distribuição de densidade de probabilidade da atenuação na vegetação a partir da densidade de probabilidade de vegetação extraída dos valores de pixels RGB de imagem de satélite. A distribuição UT de atenuação da *priori* mostrada na Figura 7.7 foi obtida utilizando a correlação linear com a distribuição do somatório de pixels RGB de vegetação de uma imagem de satélite da região

onde foram feitas medições de campo da potência recebida. A conversão entre pixels RGB de vegetação e a atenuação foi feita utilizando a regressão linear entre as mesmas que apresentou uma correlação de mais de 56%. O mesmo procedimento foi feito para se obter a distribuição *sampling* de atenuação da Figura 7.7. Utilizando o teorema de Bayes compatibilizado com a UT através da metodologia desenvolvido nesta tese foi possível combinar novas medições da distribuição *sampling* com a distribuição *prior* previamente conhecida e se obter uma nova distribuição *posteriori* de atenuação na vegetação conforme apresentado na Figura 7.7.

7.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este estudo apresentou um preditor bayesiano de cálculo de atenuação de rádio em vegetação baseado em valores de pixel de RGB de vegetação e na Transformada da Incerteza. Este método foi aplicado em dois grupos de pontos de medições cada um com sua respectiva imagem. A correlação entre atenuação e o valor de RGB nos grupos 1 e 2 foi de 0,62 e 0,56 respectivamente. O grupo 1 foi utilizado para calcular a *priori* UT de atenuação e o grupo 2 para calcular a *sampling* UT de atenuação. Para se obter a *posteriori* de atenuação foi necessário desenvolver uma técnica de compatibilização da UT com a inferência bayesiana visto que a multiplicação de UTs com pontos sigma diferentes não estava disponível no estado da arte. Este método de estimação de atenuação em vegetação pode ser útil para ferramentas de software de predição e de simulação de propagação de ondas de rádio, por exemplo em planejamento de nível cobertura de sinal em redes celulares.

CONCLUSÃO

Esta tese apresentou um preditor bayesiano para cálculo de atenuação de rádio em vegetação baseado em valores RGB de pixel de vegetação e baseado nas propriedades estatísticas da Transformada da Incerteza (UT). Este preditor foi avaliado utilizando imagens via satélite em dois ambientes distintos de vegetação na faixa de ondas centimétricas (3GHz à 30GHz). Este preditor contribui para modelos sem-empíricos de propagação em vegetação ao combinar valores de atenuação obtidas de medições em campo com estudos analíticos da geometria do ambiente de propagação.

A vegetação é uma componente intrínseca da maioria dos cenários *outdoor* de propagação de ondas rádio e estudos científicos sobre sua complexidade para análise de espalhamento e atenuação dentro do fenômeno de propagação veem sendo realizadas por décadas. Estes fatos justificam o desenvolvimento de novas técnicas como a apresentada nesta tese. Os efeitos desta complexidade de propagação aumentam com o aumento da frequência como por exemplo em espectros situados entre 3GHz e 300GHz, denominadas ondas centimétricas e ondas milimétricas. Estas faixas de frequência em espectros mais altos que os usualmente utilizados nas redes sem fio de telecomunicações estão sendo avaliadas pela comunidade científica e pelas operadoras de telecomunicações como espectros adicionais para atender a demanda crescente por banda larga móvel. Estes fatos justificam a maior relevância do estudo deste preditor no espectro de ondas centimétricas.

O preditor bayesiano de atenuação proposto nesta tese tem o intuito de simplificar ou refinar a análise e caracterização da propagação no ambiente complexo de vegetação. A Transformada da Incerteza (UT) contribui para esta simplificação ao apresentar vantagens em termos de diminuição de tempo de processamento computacional e de redução de quantidade de amostras necessárias para obtenção de resultados estatísticos de variáveis aleatórias com grau de precisão similar a outras técnicas analíticas que não usam a UT. Esta precisão foi validada conforme exemplo apresentado de forma detalhada nesta tese. A ampla e gratuita disponibilização na internet de fotos tiradas por câmeras em satélites de ambiente de vegetação é outro fator relevante que contribui para o potencial de simplificação de adoção deste preditor. O rápido crescimento de fotos tiradas via câmeras em drones tendem a aumentar a disponibilidade destas imagens. Estas vantagens justificam a utilização da UT e de imagens como forma de simplificar a análise de propagação em vegetação.

Uma outra contribuição fundamental e inovadora desta tese é a compatibilização da transformada UT com o processo de inferência Bayesiana necessária para o preditor. Esta

metodologia foi validada na resolução detalhada de um exemplo estatístico utilizando uma técnica inovadora desenvolvida nesta tese que permite a multiplicação de distribuições UT. Após amplo estudo das referências bibliográficas esta funcionalidade de multiplicação de UTs não foi encontrada no estado da arte. Esta técnica foi desenvolvida para realizar a multiplicação das distribuições *priori* (*prior*) e de amostragem (*sampling*) necessárias para obtenção da distribuição *posteriori* do teorema de Bayes. O método desenvolvido para multiplicação de distribuições UT calcula novos pontos sigma comuns, mas com diferentes pesos, para as distribuições *priori* e amostral da UT, desta forma permitindo a multiplicação de Bayes.

No processamento das imagens via satélite usadas no preditor bayesiano foi necessário excluir os pixels de prédios, filtrar os pixels de vegetação, somar os pixels de vegetação dentro da área de propagação de acordo com o ângulo de meia-potência (HPBW) das antenas TX/RX para cada azimute e normalizar o somatório de pixels de acordo com o tamanho da área capturada pela imagem em cada cenário. Este processamento resultou no somatório de pixels filtrado e normalizado que é analisado em conjunto com a atenuação da vegetação.

Este preditor bayesiano foi avaliado em dois cenários com vegetações distintas no Brasil e que apresentaram uma correlação estatística de mais de 56% entre os valores de pixel RGB e os valores de atenuação na vegetação. Estes cenários foram obtidos de três grupos de medições de potência em testes de campo que foram coletadas de trabalhos científicos anteriores e que foram analisados nesta tese. O cenário de Belo Horizonte, na região sudeste do Brasil, apresentou uma vegetação típica e as medições foram realizadas em 18 GHz. O cenário de Manaus, na região norte, apresentou uma região densamente arborizada e as medições foram coletadas em 24 GHz. As campanhas de medições coletaram atenuações em várias configurações de azimute, inclinação e diferentes distâncias entre o transmissor e o receptor o que valoriza os resultados obtidos com o preditor. As medições de Manaus foram separadas em dois grupos com o objetivo de se ter uma distribuição *priori* e outra amostral para aplicação do teorema de Bayes. Os dois grupos de medições em Manaus apresentaram correlações de 0,59 e 0,56 respectivamente enquanto que em Belo Horizonte apresentou correlação de 0,57. As análises estatísticas mostraram que mais de 30% da variância da atenuação nestes três grupos de medições podem ser explicadas pelos valores RGB dos pixels.

A UT foi aplicada na distribuição de densidade de probabilidade da atenuação dos dois grupos de medições de atenuação correlacionados a pixels de Manaus para se obter as distribuições UT *priori* e amostral de atenuação. Utilizando o modelo linear correlacionado entre pixels RGB de vegetação e valores geolocalizados de atenuação, o preditor apresentado nesta tese combinou a Transformada da Incerteza (UT) e a inferência de Bayes para encontrar

a distribuição de densidade de probabilidade da *posteriori* de atenuação em vegetação aplicada ao cenário de Manaus.

As técnicas desenvolvidas nesta tese para análise de ondas centimétricas em presença de vegetação podem ser úteis em ferramentas de predição de propagação usadas no planejamento de sistemas de rádio ou em simuladores em redes móveis usadas para validar novas tecnologias para redes sem fio. A combinação de UT e inferência de Bayes pode ser aplicada em outras áreas do conhecimento como aprendizagem de máquinas e inteligência artificial onde o teorema de Bayes já é amplamente utilizado como por exemplo na técnica de classificação de *machine learning* denominada “*Naive Bayes classifier*”.

8.1 CONTRIBUIÇÕES

O artigo “*Vegetation Image as Bayesian Predictor for Radio Propagation in Complex Environments Using Unscented Transform*” foi publicado em junho de 2018 na revista “*Journal of Microwaves, Optoelectronics and Electromagnetic Applications [JMoe]*” [35].

O artigo “*Centimeter-Wave Path Loss and Beam Combining Gain Analysis for Belo Horizonte and Manaus Environments in Brazil*”, foi apresentado em abril de 2018 na conferência EuCAP em Londres [36].

O artigo “*cmWave through vegetation: correlation of pixels and attenuation using UT and Bayes Inference*” foi apresentado em julho de 2017 na “IEEE Antennas & Propagation Society Symposium. APS/URSI, San Diego, USA” [37].

O artigo “*24 GHz cmWave Radio Propagation Through Vegetation: Suburban Tree Clutter Attenuation*” foi publicado em abril de 2016 na “*10th European Conference on Antennas and Propagation (EuCAP)*” [8].

O artigo “*Analysis and Comparison of 24 GHz cmWave Radio Propagation in Urban and Suburban Scenarios*” foi apresentado em abril de 2016 na “IEEE Wireless Communications and Networking Conference” [6].

8.2 TRABALHOS FUTUROS

Os resultados desta tese servem como base para trabalhos futuros que permitam validar a correlação de pixels e o preditor bayesiano em um cenário de vegetação controlada que pode ser executado em testes de campo ou em um simulador computacional. Em testes de

campo poderia ser utilizado um drone para controlar a obtenção das imagens aéreas da vegetação. As vantagens de se usar um simulador estão na flexibilidade para testes em diferentes cenários de vegetação e na maior facilidade da repetição dos testes. A metodologia apresentada nesta tese foi testada apenas no espectro de ondas centimétricas em ambientes suburbanos e em um ambiente controlado de simulação pode-se testar outros espectros e outros ambientes de vegetação como por exemplo aplicações de redes LPWA (low power wide area) em áreas rurais.

Outras sugestões de continuidade dos trabalhos desta tese são estudos da metodologia de correlação de pixels e do preditor bayesiano utilizando informações mais detalhadas da vegetação como por exemplo altura das árvores. Testes da metodologia correlação de pixels em cenários que não são de vegetação como por exemplo prédios em áreas urbanas. Testes da metodologia utilizando bases de dados de imagens diferentes da base do Google como por exemplo Inmet e Embrapa, ou utilizar bases de dados de imagens em infravermelho.

Como sugestão de trabalhos futuros utilizando a UT estão estudos sobre minimização de quantidade de pontos de medição de *drive test* em redes celulares utilizando a UT para determinar a localização destes pontos foram iniciados, mas não foram concluídos. O procedimento de minimização de *drive test* vem sendo objeto de pesquisa inclusive pelo 3GPP que já possui uma padronização a respeito deste tema [38]. Foram realizadas simulações iniciais utilizando a UT em cenários com medições de estudos de propagação em ambiente urbano [39][40] [41] [42] e um artigo está em fase de revisão.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] T. S. Rappaport et al., “*Millimeter Wave Wireless Communications*”, 1st Edition, Prentice Hall, 2015.
- [2] P. Mogensen et al., “*Centimeter-Wave Concept for 5G Ultra-Dense Small Cells*”, IEEE Vehicular Technology Conference (VTC), May 2014.
- [3] T. S. Rappaport et al., “*Wideband Millimeter-Wave Propagation Measurements and Channel Models for Future Wireless Communication System Design*”, IEEE Transactions on Comm., vol. 63, nº 9, Sep 2015.
- [4] S. Sun, G. R. MacCartney, M. K. Samimi, S. Nie, and T. S. Rappaport, “*Millimeter-Wave Multi-Beam Antenna Combining for 5G Cellular Link Improvement in New York City*,” 2014 IEEE International Conference on Communications (ICC), pp. 5468–5473, June 2014.
- [5] G. R. MacCartney, J. Zhang, S. Nie, and T. S. Rappaport, “*Path Loss Models for 5G Millimeter Wave Propagation Channels in Urban Microcells*,” 2013 IEEE Global Communications Conference (GLOBECOM), no. December, pp. 3948–3953, 2014.
- [6] I. Rodriguez et al., “*Analysis and Comparison of 24 GHz cmWave Radio Propagation in Urban and Suburban Scenarios*”, IEEE Wireless Communications and Networking Conference, Abril 2016.
- [7] David. L. Jones et al., “*Vegetation Loss Measurements at 9.6, 28.8, 57.6, and 96.1 GHz Through a Conifer Orchard in Washington State*”, U.S. Department of Commerce, NTIA Report 89-251, October 1989.
- [8] I. Rodriguez et al., “*24 GHz cmWave Radio Propagation Through Vegetation: Suburban Tree Clutter Attenuation*”, European Conference on Antennas and Propagation (EuCAP), Abril 2016.
- [9] M. H. B. Rezende, G. L. Ramos, et al., “*18 GHz Propagation Measurements and Analysis in Belo Horizonte/Brazil*”, IEEE-APS Topical Conference on Antennas and Propagation in Wireless Communications (APWC 2017), Verona, Italy, 2017, DOI: 10.1109/APWC.2017.8062251
- [10] JULIER, S.; UHLMANN, J. K. *A general method for approximating nonlinear transformations of probability distributions*. 1996. Eng. Dept. Univ. Oxford, Tech. Report., Oxford.
- [11] MENEZES, L. de et al. *Efficient computation of stochastic electromagnetic problems using unscented transforms*. Science, Measurement and Technology, IET, v. 2, n. 2, p. 88–95, March 2008.
- [12] J Zhang “*The calculating formulae and experimental methods in error propagation analysis*”, IEEE Trans on Reliability Vol 55, No. 2 pp 169-181, 2006.
- [13] Weisstein, Eric W. (2007, July) “*Gaussian Quadrature*” acessado em 01/03/2017 no endereço <http://mathworld.wolfram.com/GaussianQuadrature.html>
- [14] S. J. Julier, J. K. Uhlmann, and H. F. Durrant-Whyte, “*A new approach for filtering nonlinear systems*”, Proc. Amer. Contr. Conf., pp. 1628-1632, 1995
- [15] Pinheiro, Melissa de Martins, “*Aplicação da transformada de incerteza no dimensionamento de redes móveis*”, Universidade de Brasília, Brasília, DF, Brasil, Dez-2011
- [16] L.R.A.X. de Menezes et al, “*Using the Unscented Transform as an Alternative to Monte Carlo in Bit Error Rate Calculations*”, Published in: Electronics Letters, May 2013.
- [17] Fernandes, L.C., Menezes, L.R.A.X., “*Using Unscented Transform in Interference Studies*”, IEEE Antennas and Propagation Magazine, 2017
- [18] MENEZES, L. de et al. *Efficient extraction of statistical moments in electromagnetic problems solved with the method of moments*. Microwave and Optoelectronics Conference, 2007. IMOC 2007. SBMO/IEEE MTT-S International, p. 757–760, 29 2007-Nov. 1 2007.
- [19] E. A. COSTA JR., “*Propagação de incertezas em Eletromagnetismo*”, Universidade de Brasília, Brasília, DF, Brasil, Tese de Doutorado em Telecomunicações, 2009.
- [20] C. Evangelista, H. A. Junior, L. R.A.X. Menezes, “*Study of the inaccuracies in microwave filter's response with the Unscented Transform*”, SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC), 2015.
- [21] Paredes, Abraham Elias Ortega, “*Aplicação da transformada de incerteza (ut) para projeto de filtros de micro-ondas*”, Tese de Doutorado, Universidade de Brasília (UnB), fevereiro 2010.

- [22] Gelman, A., Carlin, J. B., Stern, H. S., and Rubin, D. B. et al., *Bayesian Data Analysis* (3rd ed.), Chapman and Hall Book. (2014).
- [23] Hoff, Peter D., *A First Course in Bayesian Statistical Methods* (3rd ed.), Springer Texts in Statistics. (2009).
- [24] Gelman, A., Carlin, J. B., Stern, H. S., and Rubin, D. B. et al., *Bayesian Data Analysis* (3rd ed.), Chapman and Hall Book. (2003).
- [25] “*Binomial Distribution from Wolfram Mathworld*” acessado em 30/12/2016 no endereço <http://mathworld.wolfram.com/BinomialDistribution.html>
- [26] “*Solutions to some exercises from Bayesian Data Analysis, third edition, by Gelman, Carlin, Stern, and Rubin, 22 Aug 2014*” acessado em 30/12/2016 no endereço <http://www.stat.columbia.edu/~gelman/book/solutions3.pdf>
- [27] “G-MG How many leaves on a tree?” acessado em 28/12/2016 no endereço <https://www.illustrativemathematics.org/content-standards/tasks/1138>
- [28] N.C. Rogers et al, “A generic model of 1-60 GHz radio propagation through vegetation-final report”, Radio Communications Agency, May 2002.
- [29] Rafael F. S. Caldeirinha, “*Electromagnetic Scattering from Foliage and Vegetation*”, 2005.04.13. Consortium members: University of Glamorgan UK, Instituto Politécnico de Leiria Portugal.
- [30] D. L. Ndzi et al., “*Vegetation attenuation measurements and modeling in plantations for wireless sensor network planning*”, Progress In Electromagnetics Research, 2012
- [31] W. Song et al., “*Extracting the Green Fractional Vegetation Cover from Digital Images Using a Shadow-Resistant Algorithm (SHAR-LABFVC)*”, Remote Sens, 2015
- [32] Jiapaer, G.; Chen, X.; Bao, A. *A comparison of methods for estimating fractional vegetation cover in arid regions*. Agric. Forest Meteorol. 2011, 151, 1698–1710.
- [33] *Color-Based Segmentation Using the $L^*a^*b^*$ Color Space*. Mathworks R2016b. Disponível em: < <https://www.mathworks.com/help/images/examples/color-based-segmentation-using-the-l-a-b-color-space.html>>. Acesso em: 21/10/2016.
- [34] “*Coefficient of Determination (R-Squared)*” acessado em 28/02/2017 no endereço <https://www.mathworks.com/help/stats/coefficient-of-determination-r-squared.html>
- [35] A. J. F. Loureiro, L. R.A.X. Menezes, G. L. Ramos, et al., “*cmWave through vegetation: correlation of pixels and attenuation using UT and Bayes Inference*”, Journal of Microwaves, Optoelectronics and Electromagnetic Applications (JMoe), Vol. 17, No. 2, June 2018.
- [36] G. L. Ramos, A. J. F. Loureiro, R. D. Vieira, et al., “Centimeter-Wave Path Loss and Beam Combining Gain Analysis for Belo Horizonte and Manaus Environments in Brazil”, conference EuCAP, London, april 2018.
- [37] Menezes, L.R.A.X., Loureiro, A.J.F., “*cmWave through vegetation: correlation of pixels and attenuation using UT and Bayes Inference*”, IEEE Antennas & Propagation Society Symp. APSURSI, San Diego, USA, July 2017
- [38] W. A. Hapsari, A. Umesh, et al, “*Minimization of Drive Tests Solution in 3GPP*”, IEEE Communications Magazine, Vol. 50, Issue 6, june 2012.
- [39] L. C. Fernandes, “*The Design and Development of an App to Compute Exposure to Electromagnetic Fields*”, IEEE Antennas & Propagation Magazine, April 2017.
- [40] L. C. Fernandes; A. J. M. Soares, “*Path Loss Prediction in Microcellular Environments at 900 MHz*”, AEU - International Journal of Electronics and Communications, October 2014.
- [41] R. Amorim, H. Nguyen, P. Mogensen, et al, “*Radio Channel Modeling for UAV Communication Over Cellular Networks*”, IEEE Wireless Communications Letters, Vol. 6, No. 4, August 2017.
- [42] L. C. Fernandes; A. J. M. Soares, “*Simplified Characterization of the Urban Propagation Environment for Path Loss Calculation*”, IEEE Antennas and Wireless Propagation Letters, january 2010.
- [43] J. Richter, R.F.S. Caldeirinha, et al., “*A generic narrowband model for radiowave propagation through vegetation*”, IEEE 61st Vehicular Technology Conference, 2005.
- [44] T. Chiu; K. Sarabandi, “*Electromagnetic Scattering from Short Branching Vegetation*”, IEEE Transactions on Geoscience and Remote Sensing, Vol. 38, No. 2, 2000.
- [45] D. Ndzi, L. Kamarudin, et al., “*Vegetation attenuation measurements and modeling in plantations for wireless sensor network planning*”, Progress In Electromagnetics Research B Journal, 2012.

- [46] A. Seville, K. H. Craig, “*Semi-empirical model for millimeter wave vegetation attenuation rates*”, IET Electronics Letters, august 1995.
- [47] D. M. Bradley, R. Unnikrishnan, et al., “*Vegetation Detection for Driving in Complex Environments*”, Proceedings 2007 IEEE International Conference on Robotics and Automation, 2007.
- [48] M. Samimi, K. Wang, et al., “*28 GHz Angle of Arrival and Angle of Departure Analysis for Outdoor Cellular Communications using Steerable Beam Antennas in New York City*”, IEEE 77th Vehicular Technology Conference (VTC Spring), 2013.