

VANDERLEI APARECIDO DA SILVA

**MODELAGEM COMPUTACIONAL DE CANAIS DE
COMUNICAÇÃO MÓVEL**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia Elétrica.

São Paulo

2004

VANDERLEI APARECIDO DA SILVA

**MODELAGEM COMPUTACIONAL DE CANAIS DE
COMUNICAÇÃO MÓVEL**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia Elétrica.

Área de Concentração:
Sistemas Eletrônicos

Orientador:
Prof. Dr. Paul Jean Etienne Jeszensky

São Paulo

2004

FICHA CATALOGRÁFICA

Silva, Vanderlei Aparecido da

Modelagem Computacional de Canais de Comunicação Móvel. São Paulo, Outubro de 2004.

183p.

Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle. Área de Sistemas Eletrônicos.

1. Canal de Comunicação Móvel; 2. *Path Loss*; 3. Predição de Perda de Percurso; 4. Canal com Desvanecimento; 5. Canal Rayleigh; 6. Canal Rice; 7. Simuladores de Canal; 8. Componentes Multipercurso.

I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle. Área de Sistemas Eletrônicos.

Aos meus pais, irmãos e Daniella, que têm sido incentivo primordial para meu trabalho. A paciência dispensada por vocês é própria de uma família.

AGRADECIMENTOS

Expresso meus agradecimentos ao Prof. Dr. Paul Jean E. Jeszensky pelo incentivo inicial e permanente, assim como pela incansável dedicação dispensada durante sua orientação no decorrer deste trabalho.

Ao amigo Prof. Dr. Taufik Abrão, responsável pelo início deste trabalho. Obrigado e parabéns pela sua capacidade impressionante de incentivar seus alunos.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelos dois anos de apoio financeiro prestados.

RESUMO

A modelagem computacional tem se tornado uma poderosa ferramenta utilizada mundialmente em pesquisas sobre sistemas de comunicação móvel. Em tais sistemas, a modelagem do canal é fator indispensável, pois as características de mobilidade e propagação presentes nesse tipo de sistema são responsáveis por distorções ocorridas sobre o sinal transmitido. O presente trabalho reúne os principais modelos matemáticos e computacionais de canal de comunicação móvel. Realiza-se uma abordagem histórica sobre o assunto, apresentado a natureza do problema do desvanecimento e a forma como foi modelado inicialmente. Por outro lado, apresentam-se modelos recentes, considerados eficazes do ponto de vista matemático e eficientes do ponto de vista computacional. O trabalho traz como contribuição a proposta de um novo modelo de canal com desvanecimento. Os modelos apresentados foram analisados do ponto de vista matemático por meio de suas propriedades estatísticas. Do ponto de vista numérico e computacional a análise se deu por meio de simulações. A principal conclusão obtida mostra que dois modelos com filtragem no domínio da frequência, sendo um deles o novo modelo proposto, são os mais indicados para simular formas de onda que representem um canal com desvanecimento Rayleigh. Este trabalho tem a pretensão de ser útil para pesquisadores atuantes na área de modelagem e simulação de sistemas atuais de comunicação móvel.

ABSTRACT

Computational modelling is a powerful and widely used tool for research in mobile communication systems. In such systems, the communication channel modelling is an indispensable factor, because its mobility and propagation characteristics can cause distortion over the transmitted waveform. This work contains the main mathematical and computing communication channel models. A historical cover is provided, which presents the nature of the problem and the initial modelling of the fading phenomenon. On the other hand, recent models are presented, which are mathematically effective and computationally efficient. One contribution of this work is the proposal of a new fading channel computational model, which was suitably tested and validated. The presented models were mathematically analyzed through its statistical properties. From numerical and computational point of view, the models were analyzed through several simulations. The main conclusion, from analytical and simulated results, shows that two models using frequency filtering are the best choice for the generation of multiple uncorrelated Rayleigh fading waveforms, where one of them is the new proposed model. This work can help mobile communications researchers to suitably model the communication channel in a computer simulation.

SUMÁRIO

LISTA DE FIGURAS	xii
LISTA DE TABELAS	xvi
LISTA DE ABREVIATURAS E SIGLAS	xvii
LISTA DE SÍMBOLOS	xix
1 INTRODUÇÃO	1
1.1 A MODELAGEM DO CANAL DE COMUNICAÇÃO MÓVEL	4
2 PERDA DE PERCURSO	9
2.1 PROPAGAÇÃO NO ESPAÇO LIVRE	10
2.2 PREDIÇÃO DE PERDA DE PERCURSO	11
2.2.1 Modelo empírico de Hata	13
2.2.2 Modelo COST231-Hata	14
2.2.3 Modelo COST231-Walfish-Ikegami	15
2.2.4 Modelo analítico simplificado de Xia	18
3 DESVANECIMENTO RÁPIDO E SIMULADORES	22
3.1 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO RAYLEIGH	22
3.1.1 Modelo de propagação por espalhamento de Clarke	23
3.1.1.1 Espectro de potência do canal no modelo de clarke	26
3.1.1.2 Propriedades estatísticas dos coeficientes de transmissão	28
3.1.1.3 Propriedades estatísticas associadas à envoltória	31
3.1.2 Generalização do modelo de Clarke	34
3.2 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO RICE	38
3.2.1 Modelagem matemática de canal com desvanecimento Rice	39
3.3 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO NAKAGAMI	44

3.4 MODELAGEM COMPUTACIONAL DE CANAL COM DESVANECIMENTO	
RAYLEIGH	46
3.4.1 Modelo de Jakes e suas modificações	47
3.4.1.1 Modificação segundo Dent	52
3.4.1.2 Modificação segundo Zheng	56
3.4.2 Modelo de Smith e suas modificações	60
3.4.2.1 Modificação segundo Young	62
3.5 MODELAGEM COMPUTACIONAL DE CANAL COM DESVANECIMENTO RICE ..	64
3.6 COMPONENTES MULTIPERCURSO COM CORRELAÇÃO PRÉ-DETERMINADA ..	68
3.7 O MODELO COST259	72
3.7.1 Descrição do modelo	72
3.7.1.1 Parâmetros de entrada	73
3.7.1.2 Parâmetros de saída	76
3.7.2 Sobre a geração de clusters	77
3.7.3 Sobre a ocorrência de linha de visada	79
3.7.4 Sobre a perda de percurso	82
3.7.5 Sobre a correlação temporal das componentes multipercurso	82
3.7.6 Sobre a correlação espacial entre móveis diferentes	85
4 MODELO PROPOSTO	88
4.1 APRESENTAÇÃO DO MODELO PROPOSTO	88
4.2 PROPRIEDADES ESTATÍSTICAS DO MODELO PROPOSTO	93
4.2.1 Médias estatísticas	93
4.2.2 Médias temporais	95
4.3 ADAPTAÇÃO AO MODELO DE PROPAGAÇÃO TRIDIMENSIONAL DE AULIN ...	98
5 RESULTADOS DE SIMULAÇÃO	100
5.1 TEMPO DE EXECUÇÃO DO MODELO PROPOSTO	101
5.2 PROPRIEDADES ESTATÍSTICAS DO MODELO PROPOSTO OBTIDAS	

NUMERICAMENTE	105
5.2.1 Densidades de probabilidade	105
5.2.2 Taxa de ocorrência de nulos	105
5.2.3 Taxa de cruzamento de nível e duração média dos desvanecimentos ...	107
5.2.4 Correlação entre componentes multipercurso	107
5.2.5 Autocorrelação	109
5.2.6 Correlação entre as partes real e imaginária	110
5.3 SIMULANDO COMPONENTES MULTIPERCURSO CORRELACIONADAS	111
5.3.1 Modelo de canal em sistemas com modulação multiportadora	112
5.4 SIMULANDO CANAIS COM DESVANECIMENTO RICE	116
5.5 RESULTADOS DE SIMULAÇÃO DO MODELO PROPOSTO 3D	121
5.6 COMPARAÇÕES ENTRE MODELOS	122
5.6.1 Densidades de probabilidade	122
5.6.2 Funções de correlação	124
5.6.3 Covariância entre funções amostras	127
5.6.4 Tempo de execução	129
6 DISCUSSÃO DOS RESULTADOS	130
7 CONCLUSÕES E TRABALHOS FUTUROS	138
REFERÊNCIAS BIBLIOGRÁFICAS	139
APÊNDICE A: PROCESSOS ALEATÓRIOS	146
A.1 VARIÁVEIS ALEATÓRIAS	146
A.2 PROCESSOS ALEATÓRIOS	147
A.2.1 Médias estatísticas	149
A.2.2 Médias temporais para processos WSS	150
APÊNDICE B: CÁLCULOS DE PROPRIEDADES ESTATÍSTICAS DOS MODELOS	151

B.1 CÁLCULO DAS PROPRIEDADES ESTATÍSTICAS DO MODELO DE CLARKE ...	151
B.1.1 Médias estatísticas	151
B.1.2 Médias temporais	155
B.2 CÁLCULO DAS PROPRIEDADES ESTATÍSTICAS DO MODELO DE DENT	160
B.2.1 Médias estatísticas	160
B.2.2 Médias temporais	161
B.3 CÁLCULO DAS MÉDIAS TEMPORAIS PARA O MODELO JAKES MODIFICADO	163
APÊNDICE C: CÁLCULOS DIVERSOS E PROPRIEDADES	165
C.1 CÁLCULO DA ESPERANÇA DO PRODUTO ENTRE DUAS SENÓIDES	165
C.2 RELAÇÃO ENTRE ESPECTRO DE SINAL CONTÍNUO E DE SINAL AMOSTRADO .	166
APÊNDICE D: PROCEDIMENTOS E FUNÇÕES EM LINGUAGEM MATLAB®	168
ANEXO A: ARQUIVO DE AJUDA DO MATLAB®, VERSÃO 6.0	175
ANEXO B: ARTIGO PUBLICADO NO “2004 IEEE INTERNATIONAL SYMPOSIUM ON SPREAD SPECTRUM TECHNIQUES AND APPLICATIONS”	178

LISTA DE FIGURAS

Figura 1.1	Diagrama de um canal de rádio móvel com as variações sofridas pelo sinal. Notação: λ = comprimento de onda da portadora.	6
Figura 2.1	Principais mecanismos de propagação.	9
Figura 2.2	Elipsóide de Fresnel. Notação: T_x = antena transmissora e R_x = antena receptora.	11
Figura 2.3	Perda de percurso no espaço livre.	12
Figura 2.4	Ambiente de propagação ilustrativo do modelo COST-WI.	16
Figura 2.5	Ângulo de azimute.	17
Figura 3.1	Modelo de propagação por espalhamento de Clarke. (a) Componentes de onda incidindo sobre o móvel; (b) Direção (ângulo de azimute) da n -ésima componente de onda.	24
Figura 3.2	Mapeamento da fração de potência incidente para o espectro de potência do sinal.	27
Figura 3.3	Densidade espectral de potência de um sinal sujeito ao desvanecimento (antena omnidirecional e azimute com distribuição uniforme).	28
Figura 3.4	Duração do desvanecimento, taxa de ocorrência de nulos e espaçamento entre nulos.	32
Figura 3.5	Fração média de tempo em que a envoltória do sinal permanece abaixo de um nível R .	33
Figura 3.6	Modelo tridimensional de propagação por espalhamento.	34
Figura 3.7	Uma densidade de probabilidade para o ângulo de elevação.	37
Figura 3.8	Comparação entre as DEPs nos modelos de Clarke e Aulin.	37
Figura 3.9	Comparação entre as funções de autocorrelação nos modelos de Clarke e Aulin.	38
Figura 3.10	Função densidade de probabilidade de Rice para alguns valores de K , com $b_R = 1$.	41
Figura 3.11	Função densidade de probabilidade da fase de $u(t)$.	43
Figura 3.12	Função densidade de probabilidade da fase de $u(t)$ em $t = 0$.	43
Figura 3.13	Simulador de canal com desvanecimento que utiliza fontes aleatórias	47

	filtradas.	
Figura 3.14	Distribuição de ângulo de azimute adotada por Jakes.	48
Figura 3.15	Diagrama de blocos do simulador de Jakes.	50
Figura 3.16	Densidades de probabilidade de módulo e fase do modelo de Jakes.	51
Figura 3.17	Autocorrelação normalizada obtida a partir do modelo de Jakes para 8 e 16 osciladores.	51
Figura 3.18	Função de autocorrelação e correlação cruzada entre as partes real e imaginária no modelo de Dent. Para curvas de referência veja (3.14), modelo de Clarke.	54
Figura 3.19	Covariância temporal entre funções amostras no modelo de Dent. $M_0 = 16, f_m = 100$ Hz e $T_s = 625$ μ s.	56
Figura 3.20	Covariância temporal entre funções amostras de conjuntos diferentes. $M_0 = 16, f_m = 100$ Hz e $T_s = 625$ μ s.	56
Figura 3.21	Funções de correlação temporal para o modelo Jakes modificado.	60
Figura 3.22	Algoritmo em linguagem Fortran sugerido por Smith.	60
Figura 3.23	Diagrama de blocos do modelo de Smith.	61
Figura 3.24	Diagrama de blocos do modelo de Smith após a modificação de Young.	63
Figura 3.25	Correlação cruzada normalizada em função do parâmetro a	69
Figura 3.26	Envoltória de uma componente multipercurso gerada com velocidade do móvel variante no tempo.	74
Figura 3.27	Número de clusters como função da posição do móvel.	78
Figura 3.28	Probabilidade de ocorrência de linha de visada no modelo COST259.	81
Figura 3.29	Perfil atraso-potência das componentes multipercurso.	82
Figura 3.30	Matriz de valores máximos de correlação entre as componentes multipercurso.	83
Figura 3.31	Matriz de correlação cruzada máxima. a) parte real e b) parte imaginária.	84
Figura 3.32	Trajetória tomada pelas unidades móveis na simulação. a) paralelo; b) paralelo sentido oposto e c) perpendicular.	86
Figura 3.33	Correlação espacial entre as MPC com menor atraso de cada móvel.	87
Figura 4.1	Figura utilizada para ilustrar o procedimento de interpolação.	90

Figura 4.2	Diagrama de blocos do modelo proposto.	92
Figura 5.1	Um exemplo de envoltória gerada a partir do modelo proposto. Parâmetros de simulação: $b = 1$, $f_m = 18,69$ Hz, $T_s = 1$ ms e $N = 2^{18}$.	100
Figura 5.2	a) Quantização do número de amostras; b) Tempo de execução normalizado. Média sobre 30 simulações com um conjunto de 6 componentes multipercurso em cada uma.	102
Figura 5.3	Algoritmo em pseudolinguagem do quantizador utilizado no modelo de canal. Notação: $\text{factor}(y)$ = função que devolve os fatores primos de y ; $\text{max}(x)$ = calcula o maior elemento em x .	104
Figura 5.4	a) Quantização; b) ET_{av} e ET_{avp2} . Média sobre 30 simulações com um conjunto de 6 componentes multipercurso em cada simulação.	104
Figura 5.5	Curvas teóricas e simuladas de densidades de probabilidade; $f_m = 18,69$ Hz, $T_s = 1$ ms e $N = 2^{18}$.	105
Figura 5.6	Taxa de ocorrência de nulos.	106
Figura 5.7	Taxa de cruzamento de nível e duração média dos desvanecimentos.	108
Figura 5.8	Correlação cruzada entre 4 componentes multipercurso.	108
Figura 5.9	a) parte imaginária da autocorrelação e b) parte real da autocorrelação; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.	109
Figura 5.10	Autocorrelação da parte real; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.	110
Figura 5.11	Autocorrelação da parte imaginária; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.	110
Figura 5.12	Correlação entre as partes real e imaginária.	111
Figura 5.13	Envoltória de duas componentes multipercurso com correlação cruzada normalizada igual a 0,7 (gráfico superior) e 0,1 (gráfico inferior).	112
Figura 5.14	Amplitude e fase das MPC's 1, 5 e 8 obtidas após a transformação.	114
Figura 5.15	Comportamento do erro na matriz de correlação numérica.	115
Figura 5.16	Exemplo de envoltória obtida do simulador de canal Rice. $K = 7,4$ dB.	116
Figura 5.17	Função de autocorrelação do modelo de canal Rice obtida em simulação.	118
Figura 5.18	Curvas de densidade de probabilidade e histogramas das partes: a) real e b) imaginária do simulador de canal Rice.	119

Figura 5.19	Densidade de probabilidade de fase em canal Rice obtida por simulação.	120
Figura 5.20	Densidade de probabilidade de módulo em canal Rice obtida por simulação.	120
Figura 5.21	Função de autocorrelação obtida por simulação do modelo proposto 3d; $f_m=100\text{Hz}$, $T_s=300\mu\text{s}$, $2\sigma^2=1$, $N=50$ mil, (a) $\beta_{\max}=20^\circ$ e (b) $\beta_{\max}=45^\circ$.	122
Figura 5.22	Densidade de probabilidade de módulo para os três modelos analisados. Referência: pdf Rayleigh com $2\sigma^2=1$. Notação: $\hat{\sigma}^2 = \{\text{var}(c_r(t)); \text{var}(c_i(t))\}$.	123
Figura 5.23	Densidade de probabilidade de fase para os três modelos analisados. Referência: $1/(2\pi)$.	124
Figura 5.24	Correlação cruzada entre as partes real e imaginária de uma função amostra gerada por cada modelo. Referência: $h(\tau)=0$.	125
Figura 5.25	Parte real da autocorrelação das funções amostras geradas em cada modelo. Referência: $R_c(\tau) = 2\sigma^2 J_0(2\pi f_m \tau)$.	126
Figura 5.26	Autocorrelação da parte real das funções amostras geradas em cada modelo. Referência: $g(\tau) = \sigma^2 J_0(2\pi f_m \tau)$.	126
Figura 5.27	Autocorrelação da parte imaginária das funções amostras geradas em cada modelo. Referência: $g(\tau) = \sigma^2 J_0(2\pi f_m \tau)$.	127
Figura 5.28	Parte real da covariância entre duas funções amostras obtidas em cada modelo.	128
Figura 5.29	Parte imaginária da covariância entre duas funções amostras obtidas em cada modelo.	128
Figura 5.30	ET_{av} e ET_{avp2} . Média realizada sobre 30 simulações com um conjunto de 6 funções amostras em cada uma. Notação: $N=[\text{início}:\text{incremento}:\text{fim}]$.	129
Figura B.1	Convergência da função de autocorrelação temporal quando as amplitudes das componentes de onda no modelo de Clarke são aleatórias. Notação VA = variável aleatória.	157
Figura C.1	Amostragem de um sinal limitado em banda e sua transformada de Fourier.	166

LISTA DE TABELAS

Tabela 2.1	Notação utilizada nos modelos de predição de perda de percurso.	10
Tabela 3.1	Parâmetros estimados para a distribuição de Rice.	66
Tabela 3.2	Parâmetros para o FDP médio.	67
Tabela 3.3	Parâmetros de entrada e saída do modelo COST259.	73
Tabela 3.4	Probabilidade de ocorrência de um determinado número de cluster.	80
Tabela 3.5	Probabilidade de ocorrer clusters adicionais.	80
Tabela 3.6	Valores de alguns parâmetros de cenário no modelo COST259.	81
Tabela 5.1	Fatores primos máximos nos pontos <i>a, b, c, d e e</i> .	103

LISTA DE ABREVIATURAS E SIGLAS

3G	Terceira Geração (de sistemas celulares)
BW	<i>Band Width</i>
BS	<i>Base station</i>
cdf	<i>cumulative distribution function</i>
COST	<i>European Co-operation in the Field of Scientific and Technical Research</i>
COST-WI	<i>COST-Walfish-Ikegami</i>
CW	<i>Continuous Wave</i>
DCM	<i>Directional Channel Model</i>
DEP	Densidade Espectral de Potência
DFT	<i>Discrete Fourier Transform</i>
DS-CDMA	<i>Direct Sequence Code Division Multiple Access</i>
FDP	<i>Fading-Delay Profile</i>
FFT	<i>Fast Fourier Transform</i>
FM	<i>Frequency Modulation</i>
HF	<i>High Frequency</i>
IDFT	<i>Inverse Discrete Fourier Transform</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IFFT	<i>Inverse Fast Fourier Transform</i>
IR	<i>Impulse Response</i>
ITU	<i>International Telecommunication Union</i>
JTC	<i>Joint Technical Committee</i>
LoS	<i>Line-of-Sight</i>
MPC	<i>Multipath Component</i>

MS	<i>Mobile Station</i>
NLoS	<i>Non Line-of-Sight</i>
pdf	<i>probability density function</i>
<i>rms</i>	<i>root mean square</i>
RV	<i>Random Variable</i>
SI	Sistema Internacional
TLC	Teorema do Limite Central
WH	Walsh-Hadamard
WSS	<i>Wide Sense Stationary</i>

LISTA DE SÍMBOLOS

$\langle(\cdot)\rangle$	operador média temporal para funções de tempo contínuo.
$\langle[\cdot]\rangle$	operador média temporal para funções de tempo discreto (seqüências).
\mathbf{A}	matriz de transformação utilizada para correlacionar MPCs.
A_n	atenuação sofrida pela n-ésima cópia do sinal ao incidir sobre o móvel.
A_0	atenuação sofrida pela componente especular.
b	\Rightarrow distância entre duas edificações vizinhas; \Rightarrow valor médio quadrático de uma MPC no simulador proposto.
b_{av}	potência média recebida por uma antena isotrópica ($G(\alpha) = 1$).
B_c	banda de coerência do canal.
b_R	valor médio quadrático de $u(t)$.
$b_k^{M_0} [n]$	seqüência em n que representa a k -ésima linha da matriz de Hadamard de tamanho M_0 , ou seja, é a k -ésima palavra-código WH.
$c(t)$	processo aleatório complexo que representa os coeficientes de transmissão do canal no modelo de Clarke.
$c(t)$	uma função amostra qualquer do processo aleatório $c(t)$.
$c[n]$	seqüência que representa $c(t)$ em tempo discreto.
$\tilde{c} [n]$	seqüência que representa os coeficientes de transmissão no modelo proposto.
$c_R(t)$	parte real de $c(t)$.
$c_i(t)$	parte imaginária de $c(t)$.
$c'(t)$	processo aleatório complexo que representa os coeficientes de transmissão do canal no modelo tridimensional de Aulin.
\mathbf{C}	matriz de componentes multipercurso não correlacionadas.
\mathbf{C}_T	matriz de componentes multipercurso correlacionadas.
d	distância entre as antenas transmissoras e receptoras.
d_{co}	distância de corte: máxima distância que o móvel deve estar para que haja probabilidade de linha de visada.

$E\{.\}$	operador esperança.
$\text{erf}(\cdot)$	função erro.
ET_{av}	tempo de execução médio normalizado.
ET_{avp2}	tempo de execução médio normalizado considerando somente valores de N em potência de 2.
E_0	amplitude do sinal enviado.
$F\{.\}$	operador transformada de Fourier.
f_c	freqüência da portadora (MHz no Capítulo 2, Hz nos demais capítulos).
f_m	máximo deslocamento Doppler (Hz).
f_s	freqüência de amostragem.
$f_z(z)$	função densidade de probabilidade de uma variável aleatória z .
$F_z(z)$	função distribuição de probabilidade de uma variável aleatória z .
$g(\tau)$	função de autocorrelação da parte real ou da parte imaginária do processo aleatório que representa os coeficientes de transmissão do canal.
$G(\alpha)$	ganho de antena como função do ângulo de azimute da onda incidente.
$h(\tau)$	correlação cruzada entre as partes real e imaginária do processo aleatório que representa os coeficientes de transmissão do canal.
H	matriz de Hadamard.
h_{bs}	altura da antena da estação base.
h_{ms}	altura da antena da estação móvel.
h_{rf}	altura média das edificações.
h_t	altura média absoluta dos telhados.
$I_0(\cdot)$	função de Bessel modificada de ordem zero.
$J_0(\cdot)$	função de Bessel de primeira classe e ordem zero.
K	fator Rice.
K_m	maior inteiro menor ou igual ao produto entre a máxima freqüência Doppler normalizada e o número de amostras.
L	número de subportadoras presentes em um sistema com modulação

	multiportadora.
L_{bsh}	ganho sombreamento quando a antena da BS está acima do nível dos prédios.
L_{fs}	perda de percurso no espaço livre.
L_{msd}	perda por difração múltipla nos telhados.
L_{rts}	perda por difração do telhado ao solo e por espalhamento.
M	\Rightarrow número de cópias do sinal transmitido incidindo sobre o receptor móvel; \Rightarrow número de osciladores utilizados nos modelos baseados em soma de senóides.
M_{min}	número mínimo de osciladores que deve ser utilizado nos modelos baseados em soma de senóides para que as propriedades estatísticas desejadas possam ser obtidas.
N	número de amostras geradas pelos simuladores de termo curto.
N_{cluster}	número de clusters presentes no modelo COST259.
N_{stat}	número de amostras estatísticas, ou de forma equivalente, número de funções amostras presentes na simulação de um processo aleatório.
N_t	número quantizado de amostras no simulador proposto.
N_0	valor médio do processo aleatório de Poisson x_p .
R_x	antena receptora.
$R_z(\tau)$	função de autocorrelação de um processo aleatório $z(t)$.
$S_n(f)$	densidade espectral de potência do canal em banda base.
$S_p(f)$	densidade espectral de potência do canal em banda passante.
T	intervalo de tempo sob o qual calcula-se a transformada de Fourier no modelo proposto.
$T(t)$	coeficientes de transmissão no modelo de Jakes.
T_c	inverso da largura de banda.
$T_c(t)$	parte real de $T(t)$.
T_f	resolução em frequência.
$T_k(t)$	coeficientes de transmissão no modelo de Dent.

T_s	período de amostragem.
$T_s(t)$	parte imaginária de $T(t)$.
T_x	antena transmissora.
T_0	amplitude e fase da componente especular.
$u(t)$	processo aleatório complexo que representa os coeficientes de transmissão em canal Rice.
$u[n]$	seqüência que representa $u(t)$ em tempo discreto.
v	velocidade do móvel (m/s).
\mathbf{V}	matriz de autovetores de Ψ_h .
w	largura média das ruas.
x	<p>\Rightarrow no modelo de Xia representa a distância média horizontal entre a MS e o canto onde ocorre a difração;</p> <p>\Rightarrow no COST259 representa a coordenada horizontal (abscissa) da posição da MS.</p>
$x(t)$	coeficientes de transmissão no modelo de Zheng.
$y[n]$	seqüência que representa os coeficientes de transmissão no modelo de Young.
$y_c[n]$	seqüência que representa os coeficientes de transmissão no modelo de Smith.
z	semi-eixo localizado no centro da elipsóide de Fresnel.
\mathbf{Z}	matriz diagonal de autovalores de Ψ_h .
α_n	ângulo de azimute da n -ésima onda incidente sobre o móvel.
α_0	ângulo de azimute da componente especular.
β_n	<p>\Rightarrow no modelo de Aulin representa o ângulo de elevação da n-ésima onda incidente sobre o móvel;</p> <p>\Rightarrow no modelo de Jakes original e na sua versão modificada por Dent, esta variável tem o significado de ângulo de fase.</p>
β_{\max}	ângulo de elevação máximo.
Δf	espaçamento em freqüência entre duas subportadoras subseqüentes.
$\boldsymbol{\varepsilon}_{\%}$	matriz de erro percentual.
ϕ_n	ângulo de fase inicial da n -ésima onda incidente sobre o móvel.

ϕ_0	ângulo de fase inicial da componente especular.
φ	variável aleatória uniforme no intervalo $[0, 2\pi)$ que representa a fase no domínio da frequência nos modelos IDFT.
λ	comprimento de onda da portadora.
σ	desvio padrão das partes real e imaginária do processo aleatório complexo que representa dos coeficientes de transmissão do canal.
τ	denota atraso temporal.
τ_u	atraso sofrido pela componente Rice.
τ_0	atraso sofrido pela componente especular.
ω_c	frequência da portadora (rad/s).
ω_m	máximo deslocamento Doppler (rad/s).
ω_n	deslocamento Doppler sofrido pela n-ésima cópia do sinal ao incidir sobre o móvel (rad/s).
ω_0	deslocamento Doppler sofrido pela componente especular (rad/s).
Ψ	matriz de correlação entre componentes multipercurso.
$\Psi_{i,j}$	correlação cruzada normalizada entre as componentes multipercurso i e j .

CAPÍTULO 1

INTRODUÇÃO

A análise, projeto, simulação e implementação de sistemas de comunicação requerem o entendimento detalhado do canal a ser utilizado. O conhecimento prévio do canal pode ser decisivo para a escolha da modulação e ou codificação utilizada na transmissão, para determinar a taxa e potência de transmissão, assim como a capacidade do sistema e para a escolha dos tipos de receptores e técnicas de processamento de dados utilizadas na recepção. Na impossibilidade de implementar tais sistemas devido ao elevado custo e tempo gastos, sua modelagem matemática e ou computacional tem sido uma ferramenta ampla e eficientemente utilizada na pesquisa e desenvolvimento de novas técnicas de transmissão e recepção. Como consequência, a modelagem matemática e ou computacional de canais de comunicação é fator indispensável, motivando pesquisas com o objetivo de construir modelos cada vez mais fiéis aos canais de comunicação físicos (canais reais).

Em comunicações móveis terrestres o canal de comunicação é constituído por todo o meio físico existente entre e ao redor do transmissor e receptor. Os obstáculos, ora presentes, ora ausentes, juntamente com a mobilidade presente no enlace fazem desse tipo de canal um sistema variante no tempo, porém determinístico. Mas, do ponto de vista de um observador localizado no receptor, a envoltória do sinal que está sendo recebido tem um comportamento totalmente aleatório, uma vez que é extremamente difícil para o observador prever todos os efeitos que o sinal transmitido sofrerá em cada instante de tempo. Esse comportamento aleatório sugere a modelagem estatística desses canais, que hoje é a principal ferramenta utilizada para esse fim. Por outro lado, as perdas ocorridas na potência média do sinal enviado devidas à propagação no espaço livre, difração e refração causadas pelos obstáculos têm sido modeladas através de expressões determinísticas em função da distância percorrida e frequência de propagação. Assim, apesar da elevada complexidade envolvendo os vários fenômenos físicos que ocorrem quando um sinal eletromagnético se propaga

em um canal de comunicação móvel, é possível modelar os efeitos sofridos pela envoltória desse sinal.

A teoria utilizada nos modelos matemáticos de canal de comunicação móvel teve sua origem em 1945 no trabalho minucioso de S. O. Rice [1] sobre a análise de sinais sujeitos a ruídos aleatórios. Entre outras coisas, Rice derivou expressões para as estatísticas de primeira e segunda ordem de uma corrente de ruído na saída de um filtro de banda estreita. Duas décadas depois, R. H. Clarke [2] derivou um modelo matemático, conhecido como modelo de propagação por espalhamento, para representar os efeitos sofridos por um sinal se propagando em frequência de rádio com receptor móvel. Através desse modelo, Clarke inferiu algumas propriedades estatísticas referente ao canal e chegou a uma expressão para densidade espectral de potência (DEP) do mesmo. M. J. Gans [3] revisou o trabalho de Clarke e aplicou os resultados de Rice ao modelo de Clarke, definindo completamente o processo estocástico que caracteriza um canal de comunicação móvel. Concomitantemente com os trabalhos de Clarke e Gans, W. C. Jakes [4] realizava medidas em ambiente suburbano com receptor móvel com o objetivo de verificar experimentalmente as propriedades estatísticas desse tipo de canal.

Em 1973, Aranguren e Langseth interessados em analisar o desempenho de um sistema modulado em frequência (FM, *Frequency Modulation*) em canal de rádio móvel, utilizaram em seu trabalho [5] um somatório de osciladores de baixa frequência (baseado no modelo de Clarke) como método para simular o canal nesse sistema. No ano seguinte, Jakes [4] apresentou um desenvolvimento matemático para esse método, a partir do qual propôs um simulador laboratorial de canal de rádio móvel. Um ano depois, J. I. Smith [6] também propôs um simulador laboratorial de canal, porém utilizando uma filtragem no domínio da frequência de dois processos Gaussianos complexos (por um filtro baseado na expressão de densidade espectral de potência apresentada por Clarke) e aplicando a transformada discreta de Fourier inversa (IDFT, *Inverse Discrete Fourier Transform*) ao resultado.

Com o aumento na demanda de serviços de comunicação móvel celular ocorrido na última década e o conseqüente crescimento das pesquisas nesta área, os modelos de Jakes e Smith têm sido amplamente utilizados e vários trabalhos propondo melhorias

para ambos têm sido publicados [7]-[16]. Atualmente, a maior parte dos modelos de canal de rádio móvel utilizados em pesquisa pública são versões modificadas dos modelos de Jakes e Smith.

Devido a sua natureza determinística, o modelo de Jakes apresenta dificuldades para gerar formas de ondas não correlacionadas [7], além de apresentar elevada correlação entre suas componentes de fase e quadratura [13]. Além disso, o processo resultante é não estacionário no sentido amplo (WSS, *wide-sense stationary*) [12]. Características estas que são não desejáveis em um simulador de canal de rádio-móvel. Diversas alterações foram propostas para esse modelo [7],[10]-[12],[16], na tentativa de solucionar os problemas acima citados. Em particular, a alteração proposta em [16] torna o modelo WSS e com médias estatísticas corretas. Esse modelo será analisado neste trabalho.

O modelo de Smith tem a capacidade de gerar formas de onda não correlacionadas, é WSS e possui médias estatísticas e temporais corretas. Trata-se de um modelo tradicionalmente utilizado com menor frequência no meio científico comparado ao modelo de Jakes. O motivo pode estar no uso da transformada rápida de Fourier discreta inversa (IFFT) que teoricamente, pelo uso de estruturas simples, exige o uso de seqüências com comprimento potência de dois. Porém, foram desenvolvidos algoritmos que utilizam estruturas compostas e são capazes de calcular FFT ou IFFT de seqüências cujo comprimento não é potência de dois [17], como é o caso dos algoritmos Cooley-Tukey [18]. Em [19], Frigo apresenta um método adaptativo, rápido e eficiente para o cálculo de FFT ou IFFT de seqüências de qualquer comprimento, o qual está baseado no trabalho de Cooley e Tukey [18]. Uma modificação para o modelo de Smith foi proposta em [15] e diminuiu seu esforço computacional pela metade, a qual somada ao cálculo eficiente da IDFT tornou esse modelo muito atrativo do ponto de vista de eficiência em simulação. O modelo de Smith também será analisado neste trabalho.

Paralelo a esses resultados, o grupo de pesquisa europeu COST (*European Cooperation in the Field of Scientific and Technical Research*) vem desenvolvendo simuladores de canal de rádio móvel, como o COST207 [20], COST231 [21] e o COST259 [22], capazes de reproduzir com grande fidelidade em laboratório os

fenômenos ocorridos em um canal físico real. Medidas experimentais realizadas em várias cidades européias são utilizadas para ajustar modelos matemáticos que descrevem esses fenômenos, o que contribui para aproximar o modelo da realidade. O uso desses modelos tem sido benéfico para o desenvolvimento de padrões e equipamentos em comunicações móveis [23].

1.1 A MODELAGEM DO CANAL DE COMUNICAÇÃO MÓVEL

Um canal de comunicação móvel pode ser definido como o meio físico utilizado como caminho de propagação pelo sinal recebido, em um sistema de comunicação sem fio, onde o transmissor ou o receptor está em movimento. Pode ser classificado com respeito às variações sofridas pela envoltória do sinal como: termo longo e termo curto.

Denomina-se termo longo as variações que só podem ser notadas se observadas em grande escala, ou seja, por longas distâncias ou longos períodos de tempo [24]. Constituem o termo longo a perda de percurso (*path loss*) e o sombreamento (*shadowing*). Perda de percurso é a atenuação ocorrida na potência média do sinal devido à propagação no espaço livre e às difrações e refrações causadas pelos obstáculos presentes no canal. O efeito de sombreamento ocorre devido à presença intermitente de alguns obstáculos como edificações, veículos nas ruas, presença de árvores, entre outros. A característica intermitente desses obstáculos está diretamente relacionada à mobilidade do móvel e pode ser interpretada como uma variação no valor da perda de percurso. O sombreamento, também chamado de desvanecimento lento (*slow fading*) [24],[25], tem um comportamento aleatório que pode ser representado por uma variável aleatória (RV, *random variable*) com distribuição estatística log-normal [24]. Já a perda de percurso pode ser modelada de forma determinística.

Denomina-se termo curto ou desvanecimento rápido (*fast fading*) as variações sofridas pela envoltória do sinal que só podem ser observadas em uma escala de dezenas de comprimentos de onda [24],[25]. Ocorre devido ao espalhamento local (ao redor do móvel) do sinal enviado, resultando em diversas cópias deste incidindo

sobre o móvel com diferentes atrasos. Assim, o sinal recebido será o resultado da soma destas cópias no receptor, que pode ser construtiva ou destrutiva, dependendo da posição do móvel. Desvanecimentos de 40 dB ou mais a partir do nível médio do sinal são comuns, com mínimos sucessivos ocorrendo a cada (deslocamento do móvel) meio comprimento de onda da frequência de propagação [4]. Na presença de linha de visada o desvanecimento rápido tem um comportamento aleatório que pode ser representado por uma RV com distribuição estatística de Rice. Na ausência de linha de visada o desvanecimento rápido é mais bem representado por uma RV com distribuição estatística de Rayleigh. A Figura 1.1 ilustra um diagrama do canal de rádio móvel com as possíveis formas de modelagem para cada efeito. Abaixo do diagrama estão as respectivas variações sofridas pelo sinal.

1.2 OBJETIVO E ESTRUTURA DO TRABALHO

Este trabalho tem como objetivo principal a apresentação, análise e simulação dos principais modelos computacionais de canal de comunicação móvel com desvanecimento rápido e de um novo modelo proposto. Uma análise comparativa realizada realça as qualidades e deficiências de cada modelo. Objetiva-se também apresentar os principais modelos de predição de perda de percurso.

O restante deste trabalho está estruturado da forma como segue. O Capítulo 2 aborda a predição de perda de percurso em canais de comunicação móvel. Ilustra as condições necessárias para que a propagação do sinal se dê em condições próximas às de propagação no espaço livre. Traz como assunto principal a descrição dos modelos matemáticos de predição de perda de percurso, capazes de serem implementados em computadores. Não cabe análise desses modelos, uma vez que não se dispõe de medidas experimentais para confrontar dados empíricos e analíticos. Porém, são modelos já amplamente consolidados no meio científico, sendo inclusive utilizados para dimensionar sistemas de comunicações reais, além de serem úteis na elaboração de padrões de comunicações móveis.

No Capítulo 3, inicia-se a abordagem do assunto principal (foco) deste trabalho: o desvanecimento de pequena escala. O capítulo está dedicado aos dois principais tipos

de canal de comunicação móvel quanto ao desvanecimento: Rayleigh e Rice, no que diz respeito à parte teórica e à modelagem computacional.

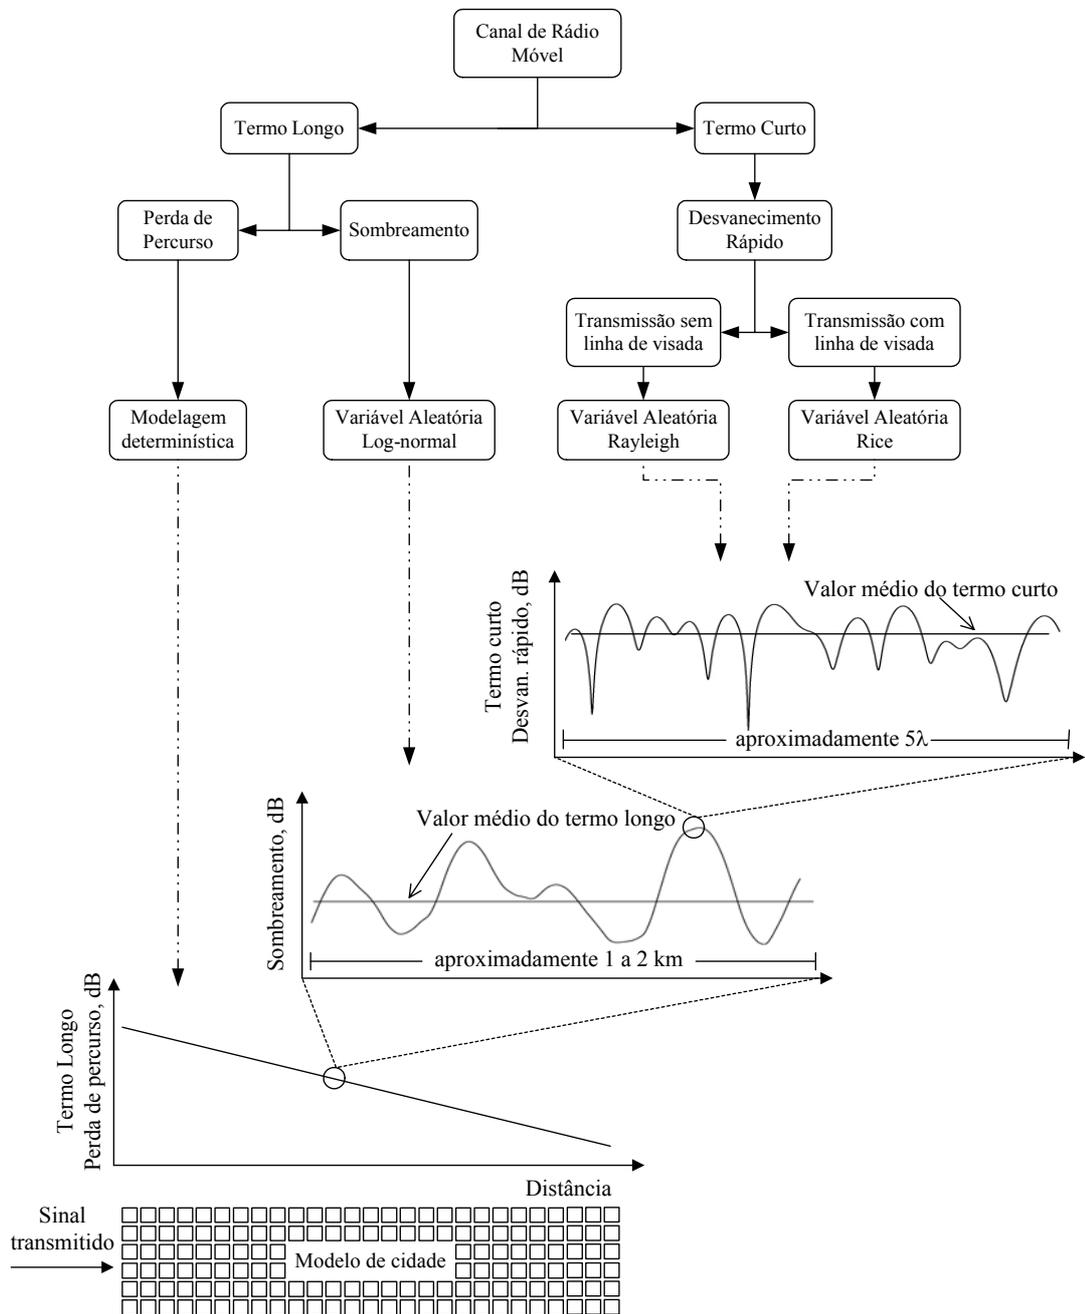


Figura 1.1: Diagrama de um canal de rádio móvel com as variações sofridas pelo sinal.

Notação: λ = comprimento de onda da portadora.

FONTE PARCIAL: SAMPEI [24], 1997, p.16.

O canal de comunicação com desvanecimento Rayleigh está matematicamente representado pelo modelo matemático de propagação bidimensional por espalhamento de Clarke, comumente conhecido apenas como modelo de Clarke, o qual encontra-se descrito em detalhes no item 3.1. Esse modelo possibilitou que uma expressão matemática para a densidade espectral de potência do canal fosse deduzida e até hoje tem sido adotado como referência teórica para canais Rayleigh. Com o objetivo de verificar a ergodicidade do modelo, suas médias estatísticas e temporais foram calculadas neste trabalho (veja Apêndice B), o que possibilitou concluir que o modelo de Clarke é ergódico em média e funções de correlação. Além disso, as propriedades estatísticas associadas à envoltória do sinal também são apresentadas. O modelo de Clarke se tornou a base para a elaboração da grande maioria dos modelos de canal com desvanecimento. Apresenta-se em seguida um modelo matemático de propagação tridimensional por espalhamento, que tem o modelo de Clarke como um caso específico. Esse modelo tridimensional se aproxima mais da realidade às custas de um aumento em complexidade.

O canal de comunicação com desvanecimento Rice pode ser matematicamente representado por meio de uma pequena modificação no modelo de Clarke, apresentada nesse capítulo no item 3.2, juntamente com as respectivas médias (calculadas) e demais propriedades estatísticas.

No item 3.3 descrevem-se alguns dos modelos computacionais de canal com desvanecimento Rayleigh amplamente utilizados no meio científico, começando pelos modelos clássicos e chegando em modelos matematicamente eficazes e computacionalmente eficientes. Quando necessário, médias estatísticas e temporais são calculadas para avaliar a eficácia matemática dos modelos, tomando como referência o modelo de Clarke. Já no item 3.4, aborda-se a modelagem computacional de canal Rice. Indica-se como gerar corretamente as amostras nesse tipo de canal e como configurar os parâmetros de simulação envolvidos.

No item 3.5 são descritos dois métodos que podem ser utilizados para correlacionar componentes multipercursos não correlacionadas, com um controle sobre o grau de correlação. Esse tópico pode ser de especial interesse na simulação de sistemas com algum tipo de diversidade, de sistemas com modulação multiportadora, ou de

qualquer outro sistema cujas componentes multipercurso apresentem algum grau de correlação. Finalmente, no item 3.6 apresenta-se uma descrição do modelo de canal COST259, no que diz respeito à configuração do modelo, assim como alguns exemplos de simulação com o mesmo. O COST259 é um modelo sofisticado que apresenta uma resposta bastante próxima da realidade, porém esse modelo não é de domínio público.

No Capítulo 4, encontra-se a principal contribuição deste trabalho, onde é proposto um novo e eficiente método para geração de coeficientes de transmissão de canal com desvanecimento. O modelo obtido a partir do método apresenta propriedades estatísticas corretas, é capaz de gerar componentes multipercursos não correlacionadas, além de exigir baixo esforço computacional. Tem sido utilizado com sucesso em diversos trabalhos [26]-[30] do grupo de pesquisas do Laboratório de Comunicações e Sinais da Escola Politécnica da Universidade de São Paulo. Além disso, deu origem a um artigo publicado no “*2004 IEEE International Symposium on Spread Spectrum Techniques and Applications*” [31]. Finalmente, o item 4.3 contempla a adaptação do modelo proposto ao modelo de propagação tridimensional.

O Capítulo 5 contém os resultados de simulação do modelo proposto, assim como de dois modelos recentemente publicados, possibilitando uma análise comparativa. Os resultados de simulação comprovam a eficiência do modelo proposto. Um exemplo de simulação de canal em sistemas com modulação multiportadora é apresentado no item 5.3. Já no item 5.4 encontram-se exemplos de simulações de canal com desvanecimento Rice a partir do modelo proposto. No item 5.5 são apresentados os resultados de simulação do modelo proposto adaptado ao ambiente de propagação tridimensional, os quais também concordam com os resultados teóricos. Finalmente, no item 5.6 apresenta-se uma comparação entre modelos através de resultados de simulação.

No Capítulo 6 apresenta-se uma discussão dos resultados obtidos e finalmente no Capítulo 7 algumas conclusões são apresentadas.

Para uma definição da nomenclatura utilizada quanto a processos aleatórios o leitor deve consultar o Apêndice A.

CAPÍTULO 2

PERDA DE PERCURSO

Em um sistema de comunicação sem fio, a potência média do sinal recebido decai com o aumento da distância entre transmissor e receptor. A atenuação que está associada às reflexões, refrações e difrações sofridas pelo sinal enviado durante o percurso até o receptor, somadas à perda por propagação no espaço livre é comumente conhecida como perda de percurso (*path loss*). A perda de percurso é constituída pela soma (em dB) entre as perdas no espaço livre e as perdas devidas aos obstáculos presentes entre transmissor e receptor, chamadas de perdas excedentes (*excess paloss*). A Figura 2.1 ilustra os principais mecanismos de propagação responsáveis por estas perdas. A perda no espaço livre pode ser determinada por uma expressão analítica bem conhecida. Já as perdas excedentes podem somente ser estimadas. Existem vários trabalhos disponíveis em literatura destinados a realizar predição de perda de percurso [21],[32]-[40]. Alguns desses trabalhos serão comentados a seguir.

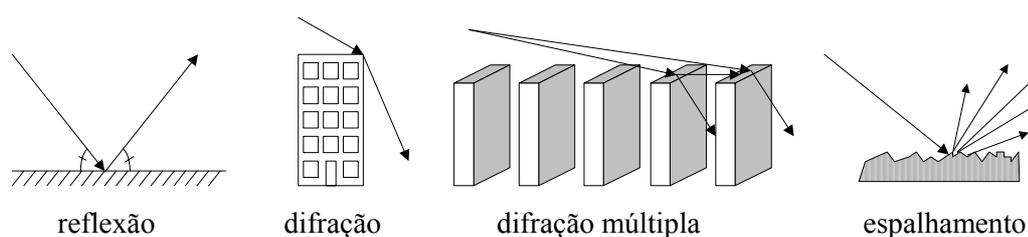


Figura 2.1: Principais mecanismos de propagação.

Os modelos de predição são relatados com respeito a vários parâmetros e unidades de medida. A Tabela 2.1 mostra um resumo desses parâmetros com seus significados e as respectivas unidades utilizadas nas equações que serão apresentadas em *dB* neste item. Nas demais equações serão utilizadas as unidades do sistema internacional (SI).

Tabela 2.1: Notação utilizada nos modelos de predição de perda de percurso.

Parâmetro	Significado	Unidade
f_c	freqüência da portadora	MHz
d	distância entre as antenas transmissora e receptora	km
h_{bs}	altura da estação base BS (<i>base station</i>)	m
h_{ms}	altura da estação móvel MS (<i>mobile station</i>)	m
h_{rf}	altura média das edificações	m
h_t	altura média dos telhados	m
w	largura das ruas	m
b	distância entre duas edificações vizinhas	m

2.1 PROPAGAÇÃO NO ESPAÇO LIVRE

Para que a propagação do sinal se dê em condições próximas às de propagação no espaço livre, o volume contido pela elipsóide de Fresnel deverá estar livre de obstruções. Define-se como elipsóide de Fresnel o lugar geométrico de todos os pontos, para os quais a soma das distâncias das duas antenas (transmissora e receptora) supera o valor da distância direta em exatamente meio comprimento de onda [41]. O plano de corte da elipsóide de Fresnel, perpendicular à direção de propagação, é chamado de primeira zona de Fresnel. A Figura 2.2 ilustra um exemplo de elipsóide e primeira zona de Fresnel. De acordo com a notação expressa na figura, a elipsóide é definida para todos os pontos no espaço que obedecem a equação: $d_1 + d_2 = d + \lambda / 2$.

O semi-eixo localizado no centro da elipsóide (ver Figura 2.2) é dado por

$$z = \frac{1}{2} \sqrt{d\lambda + (\lambda/2)^2}$$

Para valores práticos de distância entre antenas de $1 \text{ km} < d < 10 \text{ km}$ e freqüência de portadora entre 1 e 2 GHz, o valor de z se encontra na faixa entre 5 e 30 metros.

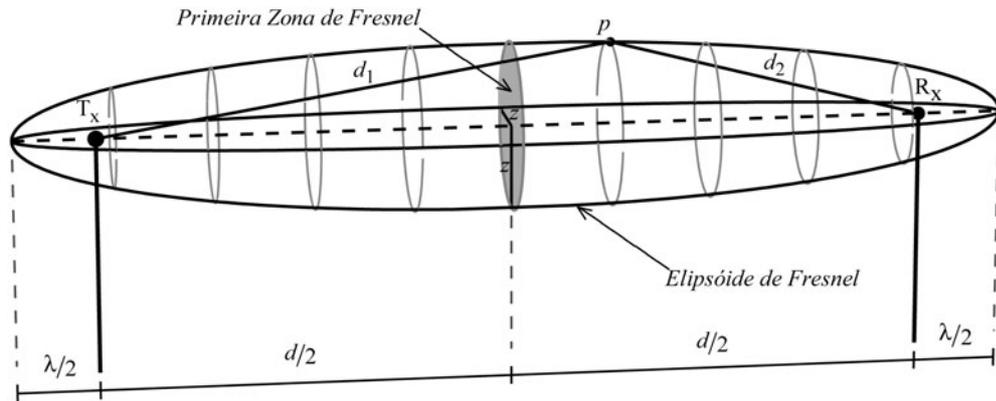


Figura 2.2: Elipsóide de Fresnel. Notação: T_x = antena transmissora e R_x = antena receptora.

Se as condições para propagação no espaço livre forem satisfeitas, a perda de percurso será

$$L_{fs} = \left(\frac{\lambda}{4\pi d} \right)^2 \quad (2.1.a)$$

ou de forma equivalente em dB

$$L_{fs} = 32,44 + 20\log_{10} f_c + 20\log_{10} d \quad (dB) \quad (2.1.b)$$

A Figura 2.3 ilustra a perda no espaço livre para uma distância entre antenas na faixa de 1 m a 10 km e frequências de portadora entre 500 MHz e 5 GHz.

2.2 PREDIÇÃO DE PERDA DE PERCURSO

Em comunicações móveis com frequência não ocorre linha de visada na comunicação, ou quando esta ocorre, pode ser momentânea devido ao movimento relativo entre transmissor e receptor, ou ainda, pode ocorrer linha de visada com obstrução de parte da elipsóide de Fresnel. Conseqüentemente, a predição da perda de percurso não pode ser feita através de (2.1.a) e as perdas excedentes devem ser estimadas. Estas estimativas têm sido realizadas de forma empírica (medidas experimentais) [32], semi-analítica (combinação de dados experimentais com expressões analíticas) [21] e analiticamente [34], constituindo os modelos de predição de perda de percurso.

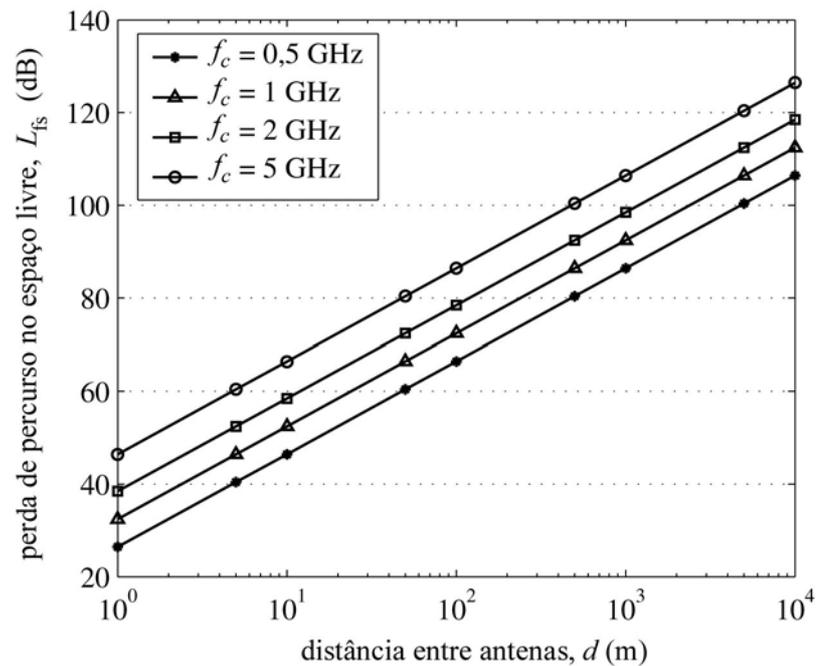


Figura 2.3: Perda de percurso no espaço livre.

Os modelos de predição são projetados tipicamente de acordo com o tamanho da célula. Um critério comumente utilizado para definição de macro, micro e picocélula está relacionado com a altura da antena da estação base [21],[22], ou seja:

- macrocélula: h_{bs} está acima da altura média das edificações vizinhas;
- microcélula: h_{bs} é aproximadamente igual ou está abaixo da altura média das edificações vizinhas;
- picocélula: a estação base está em ambiente interno e também fornece cobertura para as edificações vizinhas.

A estimativa de perda de percurso é realizada através de modelos de predição empíricos se o ambiente de propagação é pouco conhecido ou se os parâmetros dos modelos semi-determinísticos não puderem ser determinados [21]. Já os modelos de predição semi-determinísticos e analíticos permitem uma melhora na estimativa das perdas, pois são funções de vários parâmetros que podem caracterizar melhor o ambiente de propagação.

2.2.1 MODELO EMPÍRICO DE HATA

Okumura [35] traçou curvas médias para a perda de percurso baseadas em uma extensa base de dados coletados na cidade de Tóquio, Japão. O trabalho de Okumura serviu como padrão para planejamento de sistemas móveis terrestres no Japão da época [32]. Posteriormente, para fazer uso computacional dos métodos de predição de Okumura, Hata [32] derivou fórmulas empíricas a partir dos dados coletados por [35]. As equações foram formuladas considerando três tipos de cenário: urbano, suburbano e rural ou área aberta, as quais são dadas respectivamente por

$$PL_{Hata}^U = 69,55 + 26,16 \log_{10} f_c - 13,82 \log_{10} h_{bs} - a(h_{ms}) + (44,9 - 6,55 \log_{10} h_{bs}) \log_{10} d \quad (dB) \quad (2.2)$$

$$PL_{Hata}^S = PL_{Hata}^U - 2(\log_{10}(f_c/28))^2 - 5,4 \quad (dB) \quad (2.3)$$

$$PL_{Hata}^R = PL_{Hata}^U - 4,78(\log_{10} f_c)^2 + 18,33 \log_{10} f_c - 40,94 \quad (dB) \quad (2.4)$$

onde $a(h_{ms})$ é um fator de correção dependente do terreno, que para cidades de pequeno e médio porte vem a ser

$$a(h_{ms}) = (1,1 \log_{10} f_c - 0,7) h_{ms} - 1,56 \log_{10}(f_c) + 0,8 \quad (2.5)$$

e para cidades de grande porte

$$a(h_{ms}) = \begin{cases} 8,29(\log_{10}(1,54h_{ms}))^2 - 1,10, & f_c \leq 200 \text{ MHz} \\ 3,2(\log_{10}(11,75h_{ms}))^2 - 4,97, & f_c \geq 400 \text{ MHz} \end{cases} \quad (2.6)$$

O erro de predição obtido por Hata, tomando como referência as curvas de predição de Okumura, está na faixa de 1 dB, sendo independente da distância e constante para cada frequência.

Esse modelo está restrito às seguintes faixas de parâmetros:

- f_c : de 150 MHz a 1500 MHz;
- h_{bs} : de 30 m a 200 m;

- h_{ms} : de 1 m a 10 m;
- d : de 1 km a 20 km.

Uma limitação importante desse modelo está na frequência máxima de operação permitida, pois sistemas celulares atuais utilizam frequência de propagação entre 1,8 GHz e 2,0 GHz. Nesse modelo a altura da BS deve ser superior à altura média das edificações vizinhas, ou seja, não deve ser utilizado em microcélulas ou picocélulas [33]. Embora esse modelo tenha sido definido para BS com altura acima de 30 m, ele pode ser usado para alturas de BS abaixo desse valor, desde que a altura média dos edifícios da região em questão esteja abaixo do valor escolhido para a altura de BS [33]. Alguns estudos têm mostrado que devido ao menor grau de urbanização, áreas urbanas norte-americanas têm perda de percurso similar às áreas suburbanas Japonesas [42].

2.2.2 MODELO COST231-HATA

O modelo COST–Hata é uma extensão do modelo de Hata para uso em frequências (f_c) na faixa de 1.500 MHz a 2.000 MHz e está baseado no trabalho de Mogensen [33]. Os demais parâmetros (h_{bs} , h_{ms} e d) estão restritos às mesmas faixas de valores citadas no modelo de Hata.

Nesse modelo, a perda de percurso é dada por [21],[33]

$$PL_{CH} = A + B \log_{10}(d) + C_m \quad (dB) \quad (2.7)$$

onde:

$$A = 46,3 + 33,9 \log_{10}(f_c) - 13,82 \log_{10}(h_{bs}) - a(h_{ms})$$

$$B = 44,9 - 6,55 \log_{10}(h_{bs})$$

$$C_m = \begin{cases} 0 & \text{cidades de médio porte e áreas com moderada densidade de árvores.} \\ 3 & \text{centros metropolitanos.} \end{cases}$$

com $a(h_{ms})$ definida em (2.5).

Pelas mesmas razões do modelo de Hata, esse modelo não deve ser utilizado em micro ou picocélulas.

2.2.3 MODELO COST231-WALFISH-IKEGAMI

O modelo COST–WI é uma combinação dos modelos de Walfisch [36] e Ikegami [37] realizada pelos pesquisadores do grupo COST [21]. A perda de percurso é dada em função da altura média dos edifícios, da largura das ruas e distância média entre edifícios vizinhos, além dos parâmetros já citados nos outros modelos. Isto faz com que o mesmo tenha maior flexibilidade para caracterizar o ambiente de propagação. O modelo ainda é capaz de distinguir entre situações com ou sem linha de visada.

A perda de percurso para propagação com linha de visada é dada por

$$PL_{cwi}^{LOS} = 42,6 + 26 \log_{10} d + 20 \log_{10} f_c, \quad (dB) \quad d \geq 0,02 \text{ km} \quad (2.8)$$

A primeira constante em (2.8) foi escolhida de forma que a perda obtida para $d=0,02$ km seja igual à perda no espaço livre para a mesma distância. Esta equação está baseada em medidas realizadas na cidade de Estocolmo [21].

Para propagação sem linha de visada (NLoS) a perda de percurso é composta pela soma de três termos

- L_{fs} : perda no espaço livre, definida em (2.1.b);
- L_{msd} : perda por difração múltipla nos telhados (*multiple screen diffraction loss*) (veja Figura 2.1);
- L_{rts} : perda por difração do telhado ao solo (*roof-top-to-street diffraction loss*) e por espalhamento.

Veja na Figura 2.4 um ambiente de propagação ilustrativo do modelo COST–WI, onde constam os três termos de propagação e os demais parâmetros envolvidos no modelo.

A perda de percurso é então dada por

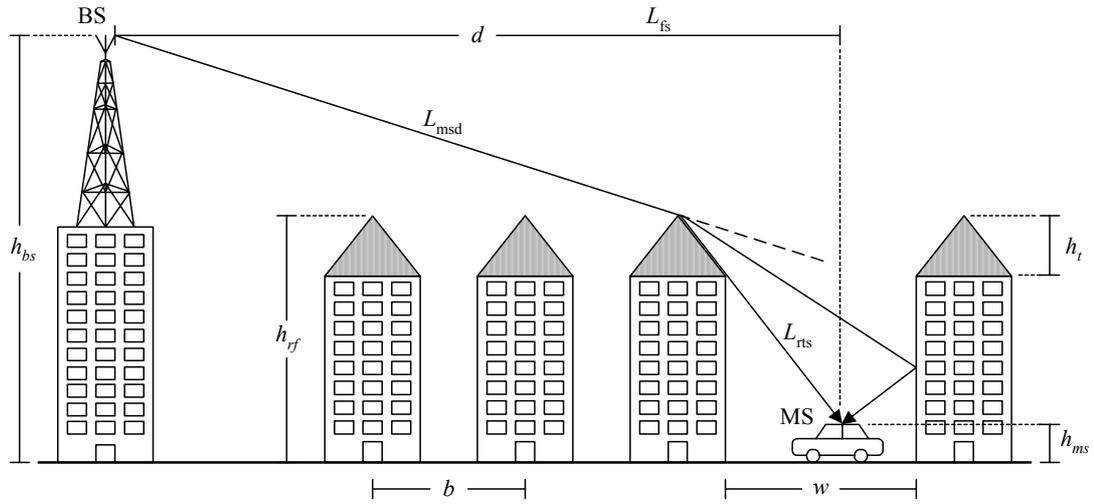


Figura 2.4: Ambiente de propagação ilustrativo do modelo COST-WI.

$$PL_{CWI}^{NLOS} = \begin{cases} L_{fs} + L_{rts} + L_{msd} & (dB), & (L_{rts} + L_{msd}) > 0 \\ L_{fs} & (dB), & (L_{rts} + L_{msd}) \leq 0 \end{cases} \quad (2.9)$$

onde

$$L_{rts} = -16,9 - 10 \log_{10} w + 10 \log_{10} f_c + 20 \log_{10} (h_{rf} - h_{ms}) + L_{ori} \quad (dB)$$

$$L_{msd} = L_{bsh} + k_a + k_d \log_{10} d + k_f \log_{10} f_c - 9 \log_{10} b \quad (dB)$$

onde

$$L_{ori} = \begin{cases} -10 + 0,354 \alpha, & 0^\circ \leq \alpha < 35^\circ \\ 2,5 + 0,075(\alpha - 35^\circ), & 35^\circ \leq \alpha < 55^\circ \\ 4,0 - 0,114(\alpha - 55^\circ), & 55^\circ \leq \alpha \leq 90^\circ \end{cases}$$

$$L_{bsh} = \begin{cases} -18 \log_{10} (1 + h_{bs} - h_{rf}) & h_{bs} > h_{rf} \\ 0 & h_{bs} \leq h_{rf} \end{cases}$$

$$k_d = \begin{cases} 18, & h_{bs} > h_{rf} \\ 18 - 15 \frac{(h_{bs} - h_{rf})}{h_{rf}}, & h_{bs} \leq h_{rf} \end{cases}$$

$$k_a = \begin{cases} 54, & h_{bs} > h_{rf} \\ 54 - 0,8(h_{bs} - h_{rf}), & h_{bs} \leq h_{rf} \text{ e } d \geq 0,5 \text{ km} \\ 54 - 0,8(h_{bs} - h_{rf}) \frac{d}{0,5}, & h_{bs} \leq h_{rf} \text{ e } d < 0,5 \text{ km} \end{cases}$$

$$k_f = -4 + \begin{cases} 0,7 \left(\frac{f_c}{925} - 1 \right), & \text{para cidades de porte médio e centros suburbanos} \\ & \text{com média densidade de árvores.} \\ 1,5 \left(\frac{f_c}{925} - 1 \right), & \text{para centros metropolitanos.} \end{cases}$$

onde α é o ângulo de azimute ilustrado na Figura 2.5. O termo L_{bsh} representa o ganho de sombreamento para os casos onde a estação base está acima do nível dos telhados. O termo k_a representa um acréscimo à perda de percurso para os casos onde a BS está abaixo do nível dos telhados. Os termos k_d e k_f controlam a dependência da perda por difração múltipla sobre os telhados para com a distância e a frequência.

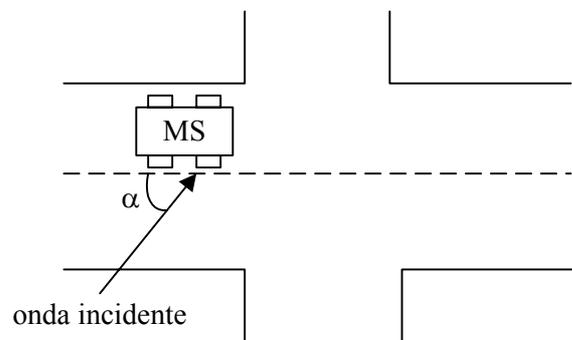


Figura 2.5: Ângulo de azimute.

Se os dados referentes aos edifícios e ruas são desconhecidos os seguintes valores são recomendados [21]

- $h_{rf} = 3 \times (\text{número de andares}) + h_t$ (m)
- $h_t = \begin{cases} 0 \text{ m,} & \text{telhados do tipo plano.} \\ 3 \text{ m,} & \text{telhados do tipo cone.} \end{cases}$

- b = de 20 a 50 m;
- $w = b/2$;
- $\alpha = 90^\circ$.

Esse modelo está restrito às seguintes faixas:

- f_c : de 800 MHz a 2000 MHz;
- h_{bs} : de 4 m a 50 m;
- h_{ms} : de 1 m a 3 m;
- d : de 0,02 km a 5 km.

Para $h_{bs} \gg h_{rf}$ o modelo apresenta erro de predição na faixa de ± 3 dB e desvio padrão de 4–8 dB. Contudo o erro de predição é grande para $h_{bs} \approx h_{rf}$ e o modelo é pobre para $h_{bs} \ll h_{rf}$ [21]. Os modelos Hata, COST–Hata e COST–WI são válidos somente para terrenos planos.

2.2.4 MODELO ANALÍTICO SIMPLIFICADO DE XIA

O modelo de propagação desenvolvido em [36],[38]–[40] fornece uma expressão analítica (não está baseada em dados empíricos) para a predição de perda de percurso em ambientes urbanos e suburbanos, podendo ser utilizado em macro e microcélulas. Tem sido testado através de medidas feitas nos Estados Unidos e Europa e em parte foi utilizado no modelo de canal COST231 [34]. Porém, esse modelo envolve integrações de múltipla dimensão para calcular a atenuação sofrida pelo sinal, dificultando sua implementação. Então, Xia [34] propôs uma versão simplificada desse modelo, tornando-o de rápida implementação. Na sua forma simplificada, o modelo tem sido adotado nos Estados Unidos pelo *Joint Technical Committee (JTC) on Wireless Access* para verificação de tecnologias de serviço de comunicação pessoal e pela *International Telecommunication Union (ITU)* visando à seleção de tecnologias para sistemas de terceira geração (3G) [34]. A flexibilidade presente nos parâmetros de entrada permite que o modelo seja facilmente adaptado a qualquer tipo de ambiente urbano e suburbano, de acordo com as necessidades.

Entre os processos que governam a propagação de rádio em ambientes urbanos e suburbanos, três foram identificados como os mais importantes: L_{fs} , L_{rts} e L_{msd} , como no modelo COST–WI (veja Figura 2.4), porém modelados de forma diferente. A soma desses três termos resulta na perda de percurso total.

O termo L_{fs} foi previamente definido em (2.1.b). Já o termo L_{rts} é dado por

$$L_{rts} = -10 \log_{10} \left(\frac{\lambda}{2\pi^2 r} \left(\frac{1}{\theta} - \frac{1}{2\pi + \theta} \right)^2 \right) \quad (2.10)$$

onde

$$\theta = \arctan \left(\frac{h_{rf} - h_{ms}}{x} \right) \quad \text{e} \quad r = \sqrt{(h_{rf} - h_{ms})^2 + x^2}$$

onde x é a distância média horizontal entre a MS e o canto onde ocorre a difração. Em geral x é tomado como sendo $w/2$, assumindo que o móvel está transitando no meio da rua.

Já o termo L_{msd} foi modelado de acordo com a relação entre a altura da antena da estação base e a altura média dos edifícios, conforme descrito a seguir.

➤ ALTURA DA ANTENA DA BS PRÓXIMA DA ALTURA MÉDIA DOS EDIFÍCIOS

Para sistemas celulares operando em áreas urbanas e suburbanas, onde os prédios têm altura aproximadamente uniforme, é conveniente colocar a antena da estação base no mesmo nível dos prédios [34]. Esse cenário pode ser aproximado fazendo $h_{bs} = h_{rf}$. Nestas condições a perda de percurso é dada por

$$PL_{XIA} = (L_{fs} - 3,01) + L_{msd} + L_{rts} \quad (dB) \quad (2.11)$$

onde

$$L_{msd} = -10 \log_{10} \left(\frac{b}{d \times 10^3} \right)^2 = 20 \log_{10} d - 20 \log_{10} b + 60 \quad (dB) \quad (2.12)$$

Um fator de 2 ($3,01 \text{ dB} = 10 \log_{10} 2$) foi incluído em (2.11) para representar os

espalhamentos locais em obstáculos nas imediações da estação base que reforçam o sinal no caminho direto.

Um exemplo foi citado pelo autor com os seguintes valores de parâmetros: $h_{rf} = 12$ m, $h_{ms} = 1,5$ m, $w = 30$ m e $b = 80$ m, representando um ambiente urbano ou suburbano de prédios com altura média de 4 andares. Nesse caso as expressões são uma simples função de d e f_c

$$PL_{XLA} = 40 \log_{10} d + 30 \log_{10} f_c + 49 \quad (dB)$$

ou seja, uma queda de 40 dB por década com a distância e 30 dB por década com a frequência, ou equivalentemente, uma dependência de $1/d^4$ com a distância e de $1/f_c^3$ com a frequência.

➤ ALTURA DA ANTENA DA BS ACIMA DA ALTURA MÉDIA DOS EDIFÍCIOS

Para providenciar maior cobertura, antenas da estação base mais altas que o nível médio dos prédios são geralmente empregadas em sistemas macrocelulares [34]. Nestas condições a perda de percurso é dada por

$$PL_{XLA} = L_{fs} + L_{msd} + L_{rts} \quad (dB) \quad (2.13)$$

onde

$$L_{msd} = -10 \log_{10} \left((2,35)^2 \left(\frac{h_{ms} - h_{rf}}{d \times 10^3} \sqrt{\frac{b}{\lambda}} \right)^{1,8} \right) \quad (dB) \quad (2.14)$$

Com os mesmos valores de parâmetros do exemplo anterior, a expressão para a perda de percurso vem a ser

$$PL_{XLA} = 38 \log_{10} d - 18 \log_{10} (h_{bs} - h_{rf}) + 21 \log_{10} f_c + 81,5 \quad (dB) \quad (2.15)$$

Nesse caso que o sinal terá uma dependência de $1/d^{3,8}$ com a distância e de $1/f_c^{2,1}$ com a frequência. Verifica-se que as perdas excedentes são menores se comparadas com o caso anterior. Com a antena da BS acima dos prédios há uma predominância

maior da perda no espaço livre.

➤ **ALTURA DA ANTENA DA BS ABAIXO DA ALTURA MÉDIA DOS EDIFÍCIOS**

Quando a antena da BS está poucos metros abaixo da altura média dos prédios, a expressão para a perda de percurso é dada por

$$PL_{XIA} = (L_{fs} - 3,01) + L_{msd} + L_{rts} \quad (dB) \quad (2.16)$$

onde

$$L_{msd} = -10 \log_{10} \left(\left(\frac{b}{2\pi(d \times 10^3 - b)} \right)^2 \frac{\lambda}{\sqrt{(h_{bs} - h_{rf})^2 + b^2}} \left(\frac{1}{\phi} - \frac{1}{2\pi + \phi} \right)^2 \right) \quad (dB) \quad (2.17)$$

$$\phi = -\arctan \left(\frac{h_{bs} - h_{rf}}{b} \right)$$

Um fator de 2 foi incluído em (2.16) pelo mesmo motivo apontado no primeiro caso.

Considerando um exemplo com os mesmos parâmetros dos exemplos anteriores, porém com a antena da estação base 5 metros abaixo do nível médio dos prédios, ou seja, $h_{BS} = 7$, a perda de percurso vem a ser

$$PL_{XIA} = 40 \log_{10} d + 40 \log_{10} f_c + 35 \quad (dB) \quad (2.18)$$

Nesse caso o sinal terá uma dependência de $1/d^4$ com a distância e de $1/f_c^4$ com a frequência. Dos três casos este último é o de maior atenuação no sinal, pois teoricamente quando a antena da BS está abaixo do nível médio dos prédios o sinal terá mais obstáculos para atravessar.

CAPÍTULO 3

DESVANECIMENTO RÁPIDO E SIMULADORES

A variação que a envoltória do sinal sofre devido ao movimento relativo entre transmissor e receptor, em um curto intervalo de tempo, é denominada desvanecimento de pequena escala, ou desvanecimento rápido. Neste capítulo aborda-se o canal de comunicação móvel quanto ao desvanecimento rápido, sendo apresentado suas características além de seus modelos matemáticos e computacionais.

Uma maneira conveniente de analisar um canal de comunicação móvel com respeito ao desvanecimento rápido é através de seus coeficientes de transmissão. O coeficiente de transmissão representa a amplitude e a fase de um sinal recebido quando uma onda contínua (CW, *continuous wave*) de amplitude unitária é transmitida [3]. Neste capítulo os termos sinal recebido e coeficientes de transmissão serão utilizados de maneira análoga. Em um canal de rádio móvel típico os coeficientes de transmissão podem ser estatisticamente representados por um processo aleatório Gaussiano complexo.

3.1 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO RAYLEIGH

Em um canal de rádio móvel, devido aos diversos obstáculos presentes entre transmissor e receptor, com frequência não há linha de visada na transmissão. Os obstáculos presentes nas vizinhanças do receptor funcionam como espalhadores do sinal enviado (veja Figura 2.1). Como resultado, chegam ao receptor diversas cópias do sinal transmitido com amplitudes (aproximadamente iguais), fases e ângulos de chegada aleatórios. Esse ambiente de propagação é conhecido como canal com desvanecimento Rayleigh. O sinal transmitido pode ainda percorrer percursos diferentes para chegar ao receptor. Nesse caso para cada percurso diferente tomado pelo sinal haverá um grupo de componentes espalhadas chegando no receptor, cada

grupo com características que são próprias de cada percurso. A componente formada pela superposição das componentes espalhadas provenientes de um determinado percurso é chamada de componente multipercurso. Em outras palavras, cada percurso diferente tomado pelo sinal pode originar uma componente multipercurso. O ambiente de propagação em questão é chamado de ambiente multipercurso, ou canal multipercurso.

Teoricamente, devido aos inúmeros espalhadores presentes na vizinhança do móvel, o número de cópias do sinal que formam uma componente multipercurso pode ser considerado infinito. Além disso, devido aos inúmeros percursos que o sinal transmitido pode percorrer até chegar ao móvel, o número de componentes multipercurso presentes em um canal multipercurso também pode ser considerado infinito. Certamente, que para o receptor esse número será finito, devido à sua capacidade limitada de discernir os atrasos e detectar componentes com amplitudes pequenas.

3.1.1 MODELO DE PROPAGAÇÃO POR ESPALHAMENTO DE CLARKE

O modelo matemático de propagação por espalhamento de Clarke tem sido amplamente aceito no meio científico. É capaz de representar matematicamente os efeitos que um sinal sofre ao propagar-se por um canal de comunicação com desvanecimento.

Considere o modelo bidimensional de propagação por espalhamento de R. H. Clarke ilustrado na Figura 3.1, onde o plano (horizontal) é representado pelo plano x - y . O sinal recebido em qualquer ponto no espaço é composto pela superposição de M ondas planas [2] provenientes do espalhamento sofrido pelo sinal na vizinhança do receptor. Seja a n -ésima onda incidindo sobre o receptor no ponto $(x=0, y=0)$ com ângulo de azimute α_n (veja Figura 3.1), amplitude A_n e com fase ϕ_n , então o sinal recebido total (em banda base) é dado por [2]

$$c = E_0 \sum_{n=1}^M A_n e^{j\phi_n} \quad (3.1)$$

onde E_0 é a amplitude do sinal enviado. As fases ϕ_n são uniformemente distribuídas de 0 a 2π e são independentes entre si e dos ângulos de chegada α_n . Teoricamente, infinitas ondas ($M \rightarrow \infty$) chegam ao receptor num determinado ponto no espaço.

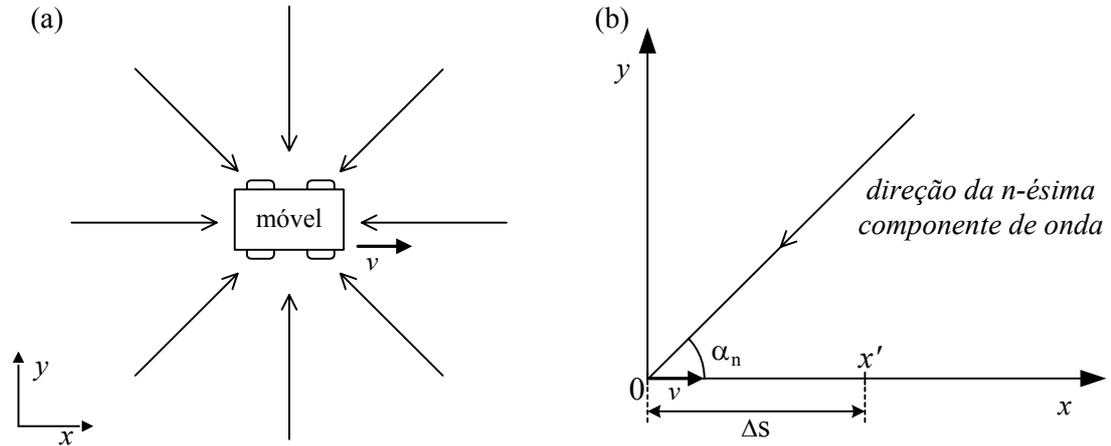


Figura 3.1: Modelo de propagação por espalhamento de Clarke. (a) Componentes de onda incidindo sobre o móvel; (b) Direção (ângulo de azimute) da n -ésima componente de onda.

Em outro ponto no espaço, distante Δs do ponto inicial na direção do eixo x , a fase da n -ésima componente de onda não será mais ϕ_n e sim $(\phi_n + 2\pi/\lambda \Delta s \cos \alpha_n)$ [2]. Se o receptor estiver em movimento com uma velocidade constante v e percorrer o espaço Δs em um intervalo $\Delta t = t - t_i$, com $t_i = 0$ (tempo de referência), então a fase da n -ésima componente de onda será

$$\phi_n + 2\pi \frac{v}{\lambda} t \cos \alpha_n \quad (3.2)$$

Note que o movimento do móvel introduz um deslocamento Doppler na n -ésima componente de onda de acordo com o seu ângulo de incidência, ou seja,

$$\omega_n = 2\pi f_m \cos \alpha_n \quad (3.3)$$

onde

$$f_m = \frac{v}{\lambda} \quad (3.4)$$

é o máximo deslocamento Doppler.

De (3.1), o sinal recebido total pode agora ser reescrito como uma função do tempo

$$c(t) = E_0 \sum_{n=1}^M A_n e^{j(\omega_n t + \phi_n)} \quad (3.5)$$

A equação (3.5) representa o modelo matemático de propagação por espalhamento de Clarke. No modelo original A_n foi considerada constante e igual para todas as componentes de onda.

Para chegar ao mesmo resultado, em [4] Jakes realizou o seguinte desenvolvimento. Considere o modelo de propagação ilustrado na Figura 3.1 e seja $E_0 \cos(\omega_c t)$ o sinal transmitido. A n -ésima cópia desse sinal ao incidir sobre o móvel terá sofrido um deslocamento Doppler ω_n relativo ao movimento do móvel, assim como uma atenuação A_n e um atraso τ_n , podendo ser representada por $E_0 A_n \cos((\omega_c + \omega_n)(t - \tau_n))$. Admitindo M cópias do sinal incidindo sobre o receptor móvel, o sinal total recebido pode ser escrito por

$$r(t) = E_0 \sum_{n=1}^M A_n \cos(\omega_c t + \omega_n t + \phi_n) \quad (3.6)$$

onde

$$\phi_n = -(\omega_c + \omega_n)\tau_n. \quad (3.7)$$

Note que $r(t)$ é caracterizado por três variáveis aleatórias: A_n , ω_n e ϕ_n , as quais são assumidas ser independentes pela própria natureza física do fenômeno de desvanecimento [12].

O sinal recebido pode ser reescrito como

$$r(t) = \text{Re} \left\{ c(t) e^{j\omega_c t} \right\} \quad (3.8)$$

onde

$$c(t) = E_0 \sum_{n=1}^M A_n e^{j(\omega_n t + \phi_n)}, \quad (3.9)$$

que é o mesmo resultado obtido por Clarke.

3.1.1.1 ESPECTRO DE POTÊNCIA DO CANAL NO MODELO DE CLARKE

A densidade espectral de potência $S_p(f)$ de um sinal desvanecido consiste de um conjunto de linhas espectrais (uma para cada onda incidente) ocorrendo na faixa $f_c \pm f_m$. Quando o número de ondas tende ao infinito a DEP passa a ser contínua na mesma faixa. Seja

$$f(\alpha_n) = f_m \cos \alpha_n + f_c, \quad (3.10)$$

e observando que $f(\alpha_n) = f(-\alpha_n)$, pode-se realizar um mapeamento entre a fração da potência total incidente no intervalo $[\alpha_n, \alpha_n + d\alpha]$ e a potência presente no intervalo $[f, f + df]$ do espectro de potência, conforme mostra a Figura 3.2. O móvel (no centro da figura inferior) está se deslocando para a direita. Sobre ele incidem ondas com diferença angular $d\alpha$, representadas pelas linhas radiais em cada quadrante. A potência presente nestas ondas será igual à área das figuras geométricas de base df indicadas pelas linhas tracejadas.

Se o ângulo de azimute α tiver densidade de probabilidade $f_\alpha(\alpha)$, então a fração da potência total recebida no intervalo $[\alpha, \alpha + d\alpha]$ será $f_\alpha(\alpha)d\alpha$. Por outro lado, a fração da potência recebida no intervalo de frequência $[f, f + df]$ será $S_p(f)df$. Desta forma, é válida a seguinte relação

$$S_p(f)|df| = b_{av}[f_\alpha(\alpha)G(\alpha) + f_\alpha(-\alpha)G(-\alpha)]|d\alpha|. \quad (3.11)$$

onde $G(\alpha)$ é o ganho da antena, b_{av} é a potência média que seria recebida por uma antena isotrópica (onde $G(\alpha) = 1$).

Tomando-se a função inversa em (3.10) tem-se $\alpha(f)$ dado por

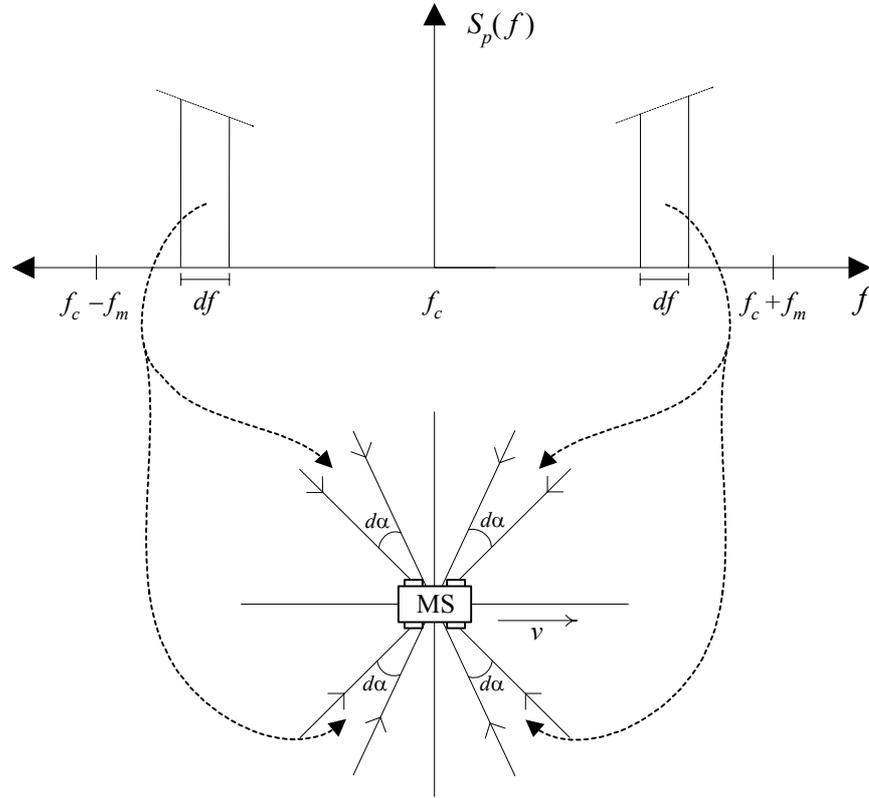


Figura 3.2: Mapeamento da fração de potência incidente para o espectro de potência do sinal.

$$\alpha(f) = \cos^{-1}\left(\frac{f - f_c}{f_m}\right),$$

sendo sua derivada dada por

$$\frac{d\alpha}{df} = \frac{-1}{f_m \sqrt{1 - \left(\frac{f - f_c}{f_m}\right)^2}}$$

Aplicando-se esse resultado em (3.11) tem-se a densidade espectral de potência do sinal recebido

$$S_p(f) = \frac{b_{av}}{f_m \sqrt{1 - \left(\frac{f - f_c}{f_m}\right)^2}} (f_a(\alpha)G(\alpha) + f_a(-\alpha)G(-\alpha)), \quad |f - f_c| \leq f_m \quad (3.12)$$

Esta equação mostra que a DEP depende, entre outros fatores, do tipo de antena

utilizada no receptor e de como se distribuem os azimutes das ondas incidentes. Para um caso específico de antena receptora omnidirecional ($G(\alpha)$ é constante e unitário), $b_{av}=1$ e ângulos de azimute distribuídos uniformemente no intervalo $[0, 2\pi)$ ($f_{\alpha}(\alpha) = 1/(2\pi)$), a DEP será

$$S_p(f) = \frac{1}{\pi f_m \sqrt{1 - \left(\frac{f - f_c}{f_m}\right)^2}}, \quad |f - f_c| \leq f_m \quad (3.13)$$

o qual está ilustrado na Figura 3.3.

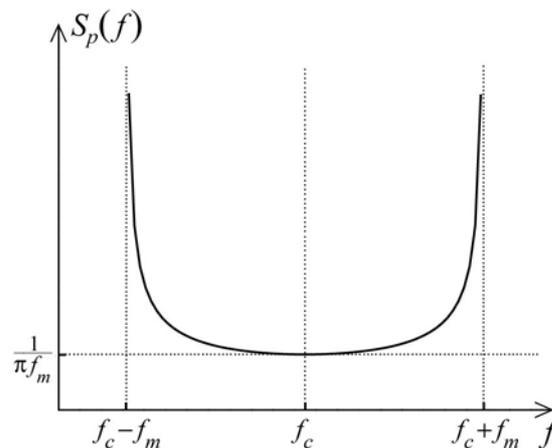


Figura 3.3: Densidade espectral de potência de um sinal sujeito ao desvanecimento (antena omnidirecional e azimute com distribuição uniforme).

Esta é uma abordagem clássica para o cálculo da DEP em canal com desvanecimento e foi introduzida primeiramente por Jakes em 1974 [4]. Porém, a DEP da equação (3.12) foi primeiramente apresentada por Clarke [2] (1968), a qual foi obtida através da transformada de Fourier da função de autocorrelação do processo aleatório proveniente do modelo de propagação por espalhamento.

3.1.1.2 PROPRIEDADES ESTATÍSTICAS DOS COEFICIENTES DE TRANSMISSÃO

Os coeficientes de transmissão no modelo de Clarke (veja equação (3.9)) são formados por uma soma (teoricamente infinita) de variáveis aleatórias

independentes. Aplicando o Teorema do Limite Central (TLC) nesta equação, verifica-se que esses coeficientes de transmissão formam um processo aleatório complexo Gaussiano.

As médias estatísticas e temporais (consulte Apêndice A para definição da notação utilizada) desse modelo estão calculadas no Apêndice B e são dadas respectivamente por:

- Médias Estatísticas:

$$E\{c(t)\} = E\{c_R(t)\} = E\{c_I(t)\} = 0 \quad (3.14.a)$$

$$E\{c_R(t)^2\} = E\{c_I(t)^2\} = \sigma^2 \quad (3.14.b)$$

$$E\{|c(t)|^2\} = 2\sigma^2 \quad (3.14.c)$$

$$g(\tau) = E\{c_R(t)c_R(t+\tau)\} = E\{c_I(t)c_I(t+\tau)\} = \sigma^2 J_0(2\pi f_m \tau) \quad (3.14.d)$$

$$h(\tau) = E\{c_R(t)c_I(t+\tau)\} = -E\{c_I(t)c_R(t+\tau)\} = 0 \quad (3.14.e)$$

$$R_c(\tau) = E\{c(t)c^*(t+\tau)\} = 2\sigma^2 J_0(2\pi f_m \tau) \quad (3.14.f)$$

onde $c_R(t) = \text{Re}\{c(t)\}$, $c_I(t) = \text{Im}\{c(t)\}$ e $J_0(2\pi f_m \tau)$ é a função de Bessel de primeira classe e ordem zero. As médias estatísticas (3.14) também podem ser encontradas em [1],[3],[4].

Em um ambiente com mais de um percurso, as componentes multipercurso podem percorrer caminhos completamente diferentes. Espera-se então que duas componentes multipercurso quaisquer sejam não correlacionadas. Nesse caso a covariância entre duas componentes multipercurso deve ser nula e a seguinte propriedade pode ser adicionada

$$C_{c_i, c_j}(\tau) = E\{c_i(t)c_j^*(t+\tau)\} - E\{c_i(t)\}E\{c_j^*(t)\} = 0, \quad i \neq j \quad (3.14.g)$$

onde os índices i e j representam o i -ésimo e j -ésimo percurso.

De acordo com a relação de Wiener-Khinchine a densidade espectral de potência de um processo aleatório WSS e sua função de autocorrelação são pares de

transformada de Fourier. Seja $S_n(f) = S_p(f + f_c)$ (veja (3.13)) a densidade espectral de potência em banda base, então de (3.14.f) deve ser válida a seguinte relação

$$S_n(f) = F\{J_0(2\pi f_m \tau)\} \quad (3.15)$$

O cálculo da Transformada de Fourier em (3.15) pode ser encontrado em [2].

Uma vez que o processo aleatório em questão é Gaussiano, as propriedades apresentadas em (3.14) são suficientes para defini-lo completamente. As propriedades (3.14.a), (3.14.d) e (3.14.f) mostram que $c(t)$ é estacionário no sentido amplo [43]. As propriedades (3.14.b) e (3.14.e) mostram que as partes real e imaginária do processo têm a mesma variância e são independentes, respectivamente. Das propriedades (3.14.a), (3.14.b) e (3.14.e) pode-se concluir que nesse processo, para qualquer instante t , o ângulo de fase $\angle c(t)$ é uma RV com distribuição uniforme no intervalo $[0, 2\pi)$ e o módulo $|c(t)|$ uma RV Rayleigh [43] com função densidade de probabilidade (pdf, *probability density function*) e função distribuição de probabilidade (cdf, *cumulative distribution function*), dadas respectivamente por

$$f_{|c|}(x) = \begin{cases} \frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right); & x \geq 0 \\ 0; & \text{caso contrário} \end{cases} \quad (3.16)$$

$$F_{|c|}(x) = 1 - \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (3.17)$$

- Médias Temporais

$$\begin{aligned} \langle c(t) \rangle &= E\{c(t)\} \\ \overline{R}_c(\tau) &= R_c(\tau) \\ \overline{g}(\tau) &= g(\tau) \\ \overline{h}(\tau) &= h(\tau) \end{aligned} \quad (3.18)$$

Como as médias temporais e estatísticas são iguais para qualquer função amostra,

esse processo é ergódico em média, função de autocorrelação e correlação cruzada entre as partes real e imaginária. Em outras palavras, qualquer média estatística desse processo pode ser obtida analisando somente uma função amostra do mesmo. Na prática, fenômenos físicos representando dados aleatórios são geralmente ergódicos, como os dados coletados no campo de comunicações móveis [44]. Na análise de sinais aleatórios em comunicações móveis é necessário trabalhar quase que exclusivamente com funções amostras [44] (certamente que as médias temporais são bem mais fáceis de serem medidas que as médias estatísticas). Medidas realizadas em [45] com o objetivo de comprovar experimentalmente as propriedades estatísticas presentes em um canal de comunicação móvel foram realizadas considerando diversos quadros de tempo (funções amostras). Assim, parece razoável esperar que no processo aleatório gerado por um simulador computacional de canal (termo curto) as propriedades estatísticas possam ser determinadas através de uma simples função amostra, i.e., que o simulador seja ergódico.

Nos simuladores de termo curto apresentados neste capítulo será considerado que cada função amostra $c(t)$ de um mesmo processo aleatório $c(t)$ pode representar uma componente multipercurso. Desta forma os termos função amostra e componente multipercurso serão utilizados analogamente.

3.1.1.3 PROPRIEDADES ESTATÍSTICAS ASSOCIADAS À ENVOLTÓRIA

São considerados nulos de um sinal desvanecido os pontos de mínimo presentes em sua envoltória. Eles ocorrem espaçados por aproximadamente $\frac{1}{2}$ comprimento de onda do sinal transmitido e podem chegar à profundidade de 40 dB ou mais [4]. Assim, para um sinal transmitido a uma frequência de 1 GHz um movimento de 15 cm realizado pelo móvel pode causar uma transição no sinal da ordem de 40 dB.

Se um nulo ocorre a cada $\frac{1}{2}$ comprimento de onda então o intervalo de tempo aproximado entre a ocorrência de um nulo e outro pode ser definido por

$$\Delta t \cong \frac{\lambda/2}{v} \cong \frac{1}{2f_m}$$

Desta relação pode-se chegar à taxa (aproximada) de ocorrência de nulos

$$f_{\text{nulos}} \cong 2f_m \quad (\text{nulos} / s) \quad (3.19)$$

Define-se taxa de cruzamento de nível o valor esperado para o qual a envoltória cruza um nível específico R , na direção positiva [3],[4]

$$\overline{N}_R(f_m, \rho) = \sqrt{2\pi} f_m \rho e^{-\rho^2} \quad (3.20)$$

onde ρ é a razão entre o nível R e o valor *rms* (root mean square) do sinal

$$\rho = \frac{R}{\sqrt{2\sigma^2}}$$

Já o intervalo de tempo no qual a envoltória de um sinal fica abaixo de um certo nível R é definido como duração do desvanecimento [3],[4]. A Figura 3.4 ilustra uma envoltória típica de um sinal com desvanecimento, ilustrando os conceitos de espaçamento entre nulos, taxa de ocorrência de nulos ($R = -10$ dB) e duração do desvanecimento.

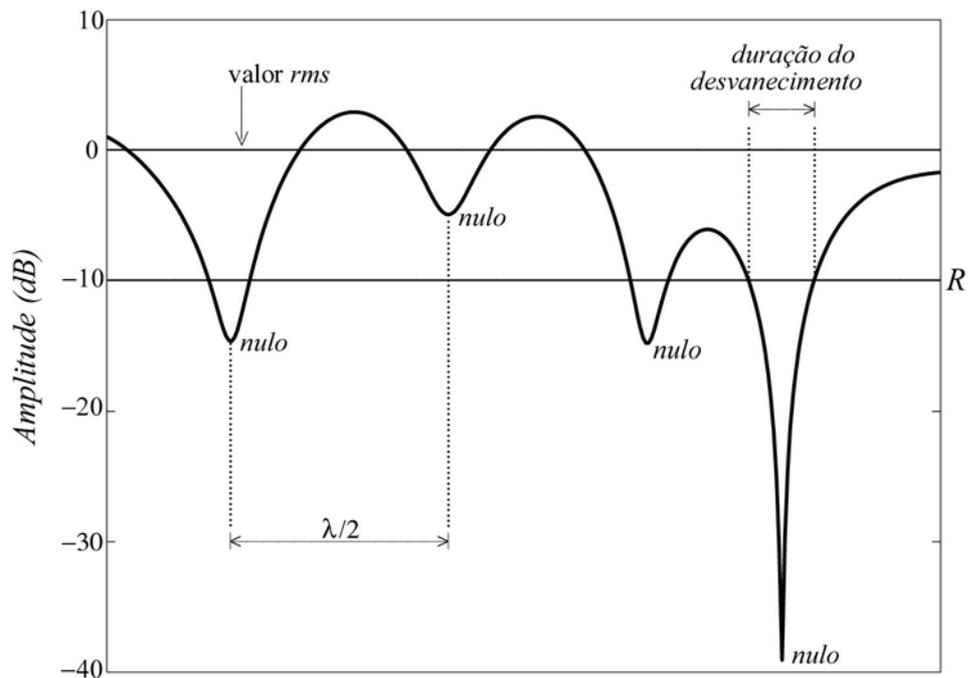


Figura 3.4: Duração do desvanecimento, taxa de ocorrência de nulos e espaçamento entre nulos.

A duração média dos desvanecimentos (*average fade duration*) é dada por [3],[4]

$$\overline{AFD}(f_m, \rho) = \frac{e^{\rho^2} - 1}{\sqrt{2\pi} \rho f_m} \quad (3.21)$$

A fração média de tempo que a envoltória do sinal ficará abaixo de um determinado nível R pode ser obtida pelo produto entre a taxa de ocorrência do desvanecimento e a duração média dos desvanecimentos

$$\eta(\rho) = \overline{N}_R(f_m, \rho) \times \overline{AFD}(f_m, \rho) = 1 - e^{-\rho^2} \quad (3.22)$$

Verifica-se que (3.22) não depende da máxima frequência de deslocamento Doppler. Nota-se também que (3.22) e (3.17) são iguais, o que significa que o produto entre \overline{N}_R e \overline{AFD} é a probabilidade de $|c(t)| < R$. A Figura 3.5 ilustra esse conceito através de (3.22). Nota-se por exemplo, que em 99% do tempo, o nível do sinal permanece acima de -20 dB. Esta informação pode ser utilizada no cálculo da probabilidade de ocorrer falha na transmissão.

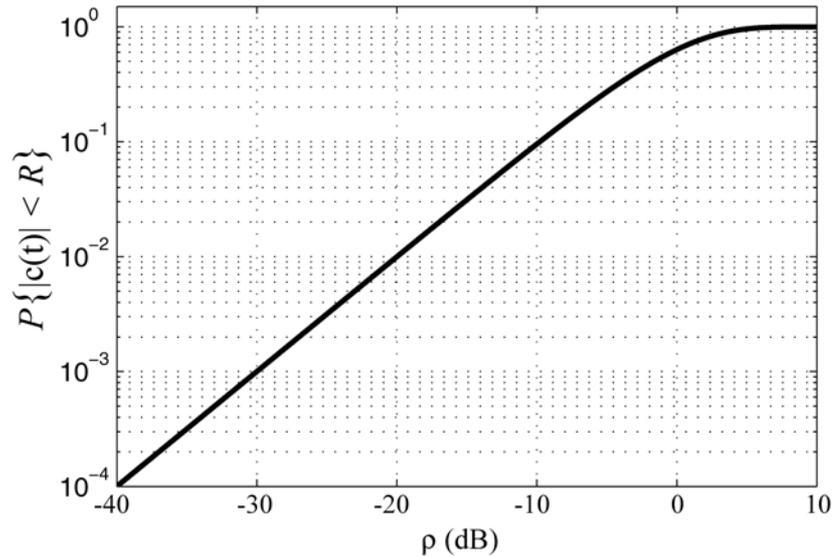


Figura 3.5: Fração média de tempo em que a envoltória do sinal permanece abaixo de um nível R .

3.1.2 GENERALIZAÇÃO DO MODELO DE CLARKE

Em ambiente urbano, as componentes de onda espalhadas não necessariamente se propagam horizontalmente. A difração que ocorre no topo do telhado das edificações faz com que a n -ésima componente de onda chegue no receptor com um ângulo de elevação β_n . Com o objetivo de investigar a influência desta propagação não horizontal no sinal recebido, Tor Aulin [46] propôs um modelo matemático tridimensional de propagação por espalhamento que tem o modelo Clarke (bidimensional) como um caso especial. A Figura 3.6 ilustra o modelo de Aulin.

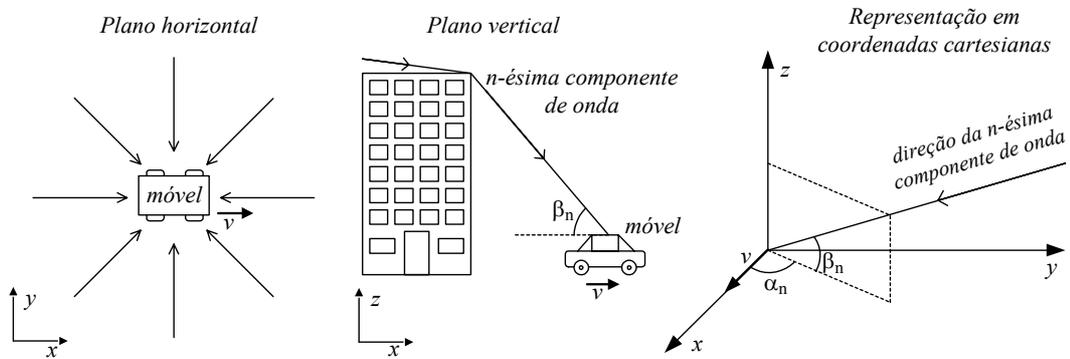


Figura 3.6: Modelo tridimensional de propagação por espalhamento.

Assim como no modelo de Clarke, o sinal recebido total em um determinado ponto no espaço pode ser escrito como

$$\mathbf{c} = E_0 \sum_{n=1}^M A_n e^{j\phi_n} \quad (3.23)$$

Em outro ponto no espaço, distante Δs do ponto inicial na direção do eixo x e sem componente de deslocamento no eixo z , a fase da n -ésima componente de onda não será mais ϕ_n e sim $(\phi_n + 2\pi/\lambda \Delta s \cos \alpha_n \cos \beta_n)$ [2]. Se o receptor estiver em movimento com uma velocidade constante v e percorrer o espaço Δs em um intervalo $\Delta t = t - t_i$, com $t_i = 0$ (tempo de referência), então a fase da n -ésima componente de onda será

$$\phi_n + 2\pi \frac{v}{\lambda} t \cos \alpha_n \cos \beta_n = \phi_n + 2\pi f_m t \cos \alpha_n \cos \beta_n = \omega_n' t + \phi_n \quad (3.24)$$

onde agora $\omega'_n = 2\pi f_m \cos \alpha_n \cos \beta_n$.

De (3.23), o sinal recebido total pode agora ser reescrito como uma função do tempo

$$c'(t) = E_0 \sum_{n=1}^M A_n e^{j(\omega'_n t + \phi_n)} \quad (3.25)$$

A equação (3.25) representa o modelo matemático tridimensional de propagação por espalhamento, onde α_n , β_n , ϕ_n e A_n são variáveis aleatórias estatisticamente independentes.

A esperança de $c'(t)$ é dada por

$$\begin{aligned} E\{c'(t)\} &= E_0 \sum_{n=1}^M A_n E\{e^{j\omega'_n t}\} E\{e^{j\phi_n}\} = 0 \\ \Rightarrow E\{\text{Re}\{c'(t)\}\} &= 0 = E\{\text{Im}\{c'(t)\}\} \end{aligned} \quad (3.26)$$

A função de autocorrelação $c'(\tau)$ pode ser encontrada substituindo (3.25) em (B.13), resultando em

$$\begin{aligned} R_c(\tau) &= E_0^2 \sum_{n=1}^M E\{|A_n|^2\} E\{e^{j2\pi f_m \tau \cos \alpha_n \cos \beta_n}\} \\ &= E_0^2 \sum_{n=1}^M E\{|A_n|^2\} \iint e^{j2\pi f_m \tau \cos \alpha_n \cos \beta_n} f_\alpha(\alpha_n) f_\beta(\beta_n) d\alpha_n d\beta_n \\ &= E_0^2 \sum_{n=1}^M E\{|A_n|^2\} \int J_0(2\pi f_m \tau \cos \beta_n) f_\beta(\beta_n) d\beta_n \\ &= 2\sigma^2 \int J_0(2\pi f_m \tau \cos \beta) f_\beta(\beta) d\beta \end{aligned} \quad (3.27)$$

onde $f_\alpha(\alpha_n)$ e $f_\beta(\beta_n)$ são as pdfs de α_n e β_n , respectivamente. Com procedimento semelhante, verifica-se que

$$g_R(\tau) = g_I(\tau) = \frac{1}{2} R_c(\tau) \quad (3.28)$$

$$h'(\tau) = 0 \quad (3.29)$$

Aplicando o TLC em (3.25) verifica-se que o processo continua sendo Gaussiano complexo. Assumindo que $f_\beta(\beta)$ em (3.27) não muda com o tempo, esse processo

pode ser considerado WSS. Além disso, de (3.26), (3.28) e (3.29) pode-se concluir que sua envoltória tem distribuição Rayleigh e sua fase é uniformemente distribuída de 0 a 2π , como no modelo de Clarke. Porém, fica claro de (3.27) que a influência do ângulo de elevação está na função de autocorrelação do processo. Conseqüentemente, o espectro de potência resultante sofrerá alterações (comparado ao espectro obtido por Clarke).

Em princípio, a DEP para esse modelo pode ser calculada utilizando a relação de Wiener-Khinchine

$$2\sigma^2 S_n'(f) = F \left\{ 2\sigma^2 \int J_0(2\pi f_m \tau \cos \beta) f_\beta(\beta) d\beta \right\} \quad (3.30)$$

Porém, dependendo da forma assumida pela função $f_\beta(\beta)$, o cálculo da transformada de Fourier de (3.30) pode não ser direto.

De acordo com Aulin [46], a pdf para o ângulo de elevação definida por

$$f_\beta(\beta) = \begin{cases} \frac{\cos \beta}{2 \text{sen} \beta_{\max}}, & |\beta| \leq \beta_{\max} \leq \frac{\pi}{2} \\ 0, & \text{caso contrário} \end{cases} \quad (3.31)$$

e ilustrada na Figura 3.7, pode ser realística para pequenos valores de β_{\max} (ângulo de elevação máximo) e torna possível o cálculo da DEP em (3.30)

$$2\sigma^2 S_n'(f) = F \left\{ \frac{2\sigma^2}{2 \text{sen} \beta_{\max}} \int_{-\beta_{\max}}^{\beta_{\max}} J_0(2\pi f_m \tau \cos \beta) \cos \beta d\beta \right\} \quad (3.32)$$

resultando em [46]

$$S_n'(f) = \begin{cases} 0, & |f| > f_m \\ \frac{1}{2 f_m \text{sen} \beta_{\max}}, & f_m \cos \beta_{\max} \leq |f| \leq f_m \\ \frac{1}{2\pi f_m \text{sen} \beta_{\max}} \left(\frac{\pi}{2} - \arcsen \frac{2 \cos^2 \beta_{\max} - 1 - \left(\frac{f}{f_m}\right)^2}{1 - \left(\frac{f}{f_m}\right)^2} \right), & |f| \leq f_m \cos \beta_{\max} \end{cases} \quad (3.33)$$

Observe que no modelo bidimensional a densidade espectral de potência tende ao infinito quando a frequência tende ao máximo deslocamento Doppler. Já no modelo tridimensional o espectro assume valor finito nesse mesmo ponto, além de ser constante durante uma faixa de frequência próxima de f_m . É o que ilustra a Figura 3.8 (gráfico à direita) para $\beta_{\max} = 20^\circ$. Teoricamente, quanto menor o valor de β_{\max} , maior a proximidade entre os dois modelos. Isto pode ser verificado na Figura 3.8, gráfico à esquerda, onde para $\beta_{\max} = 5^\circ$ as curvas de DEP praticamente se sobrepõem.

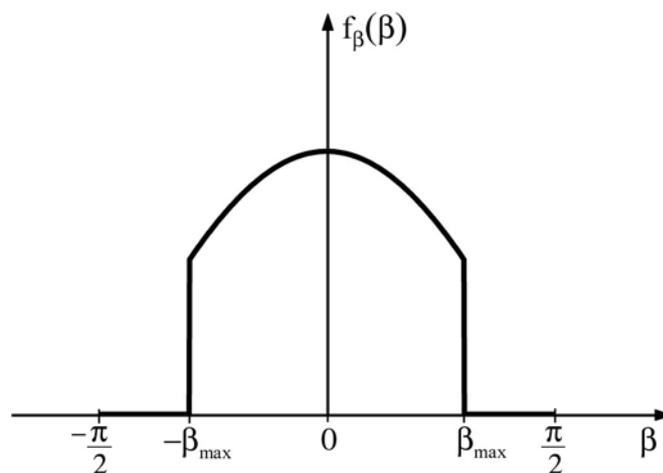


Figura 3.7: Uma densidade de probabilidade para o ângulo de elevação.

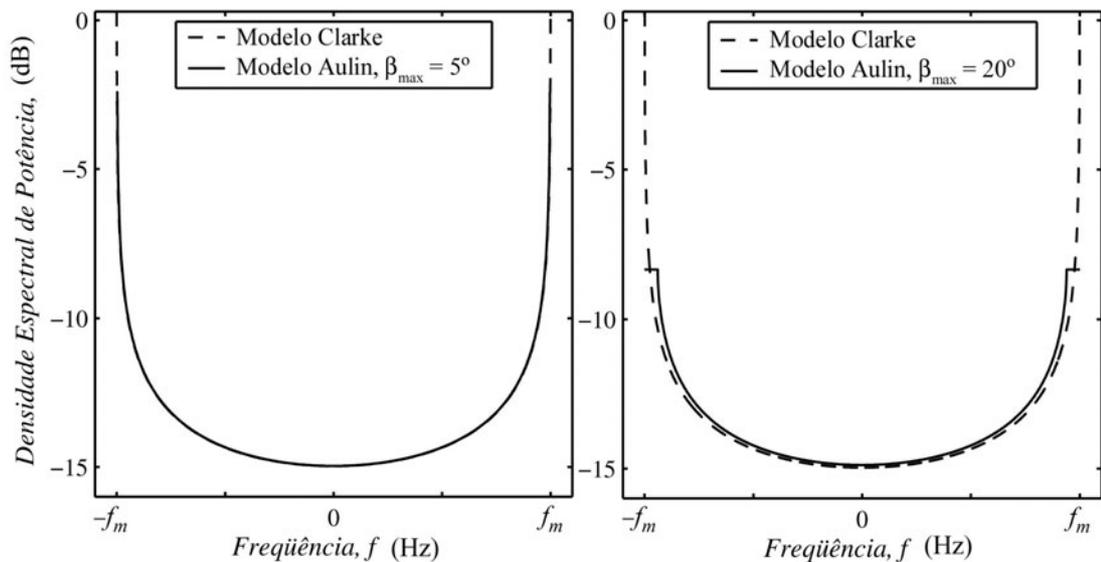


Figura 3.8: Comparação entre as DEPs nos modelos de Clarke e Aulin.

Finalmente, a Figura 3.9 ilustra uma comparação entre as funções de autocorrelação

nos modelos de Clarke e Aulin (calculado numericamente de (3.27) e (3.31)). Observe que um aumento no ângulo máximo de elevação faz com que a correlação entre as amostras se aproxime do zero mais rapidamente.

No Capítulo 4 será mencionado como incorporar esse modelo tridimensional de propagação ao simulador computacional proposto.

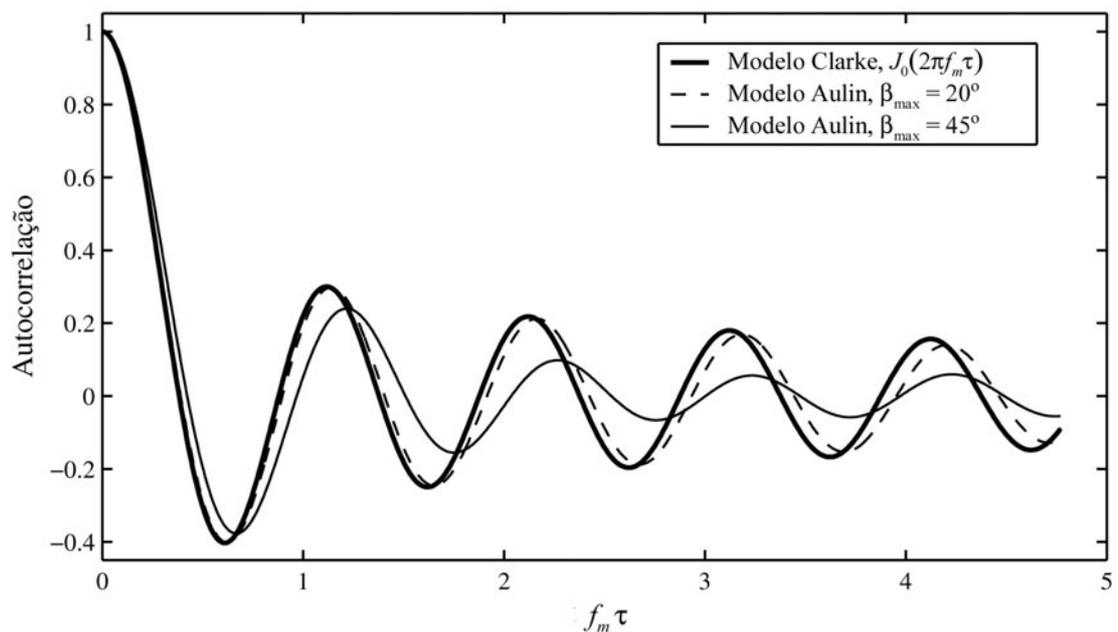


Figura 3.9: Comparação entre as funções de autocorrelação nos modelos de Clarke e Aulin.

3.2 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO RICE

Quando um número significativo de componentes de onda estão incidindo sobre o móvel com amplitudes aproximadamente iguais e ângulos de chegada uniformemente distribuídos (modelo de espalhamento de Clarke) devido ao espalhamento sofrido pelo sinal na vizinhança do móvel, o sinal no receptor terá uma envoltória com distribuição Rayleigh. Porém, se houver uma componente incidindo sobre o móvel, diretamente ou por reflexão, com uma potência significativamente maior que as demais, então o sinal no receptor terá uma envoltória com distribuição Rice. Esta componente com potência predominante recebe o nome de componente direta ou componente especular, ou ainda componente LoS [46],[47]. Essa situação de propagação tem sido comumente observada em ambiente microcelular [48], [49],

podendo ocorrer em macrocélulas quando houver linha de visada na transmissão, em canais de comunicação móvel via satélite, entre outros [50].

3.2.1 MODELAGEM MATEMÁTICA DE CANAL COM DESVANECIMENTO RICE

A componente especular pode ser modelada matematicamente como sendo uma das inúmeras cópias do sinal que incidem sobre o móvel no modelo de Clarke/Jakes (veja equação (3.6)), porém com amplitude, fase e frequência Doppler determinísticas, sendo dada por [46]

$$r_0(t) = \text{Re}\{T_0(t)e^{j\omega_c t}\} = A_0 \cos(\omega_c t + \omega_0 t + \phi_0) \quad (3.34)$$

onde $\omega_0 = 2\pi f_m \cos \alpha_0$ é a frequência Doppler (rad/s) da componente especular, α_0 o ângulo de azimute, ϕ_0 o ângulo de fase inicial e

$$\begin{aligned} T_0(t) &= m_R(t) + jm_I(t) = A_0 e^{j(\omega_0 t + \phi_0)} \\ \Rightarrow m_R(t) &= A_0 \cos(\omega_0 t + \phi_0) \quad \text{e} \quad m_I(t) = A_0 \sin(\omega_0 t + \phi_0) \\ \Rightarrow A_0^2 &= m_R^2 + m_I^2 \end{aligned} \quad (3.35)$$

No ambiente de propagação em questão, o sinal recebido será formado pela soma entre as componentes procedentes do espalhamento na vizinhança do móvel e a componente especular. Desta forma, os coeficientes de transmissão podem ser modelados como

$$u(t) = \underbrace{A_0 e^{j(\omega_0 t + \phi_0)}}_{\text{componente especular}} + \underbrace{\sum_{n=1}^M A_n e^{j(\omega_n t + \phi_n)}}_{\text{componentes do espalhamento}} = T_0(t) + c(t) \quad (3.36)$$

onde $c(t)$ tem propriedades estatísticas definidas por (3.14). Note que $u(t)$ é um processo aleatório Gaussiano complexo com valor médio igual a $T_0(t)$. Esse processo não é estacionário nem mesmo no sentido amplo, já que seu valor médio é uma função do tempo.

O valor médio quadrático de $u(t)$ é dado por

$$\begin{aligned}
b_R &= E\{u(t)u^*(t)\} = E\{(T_0(t) + c(t))(T_0^*(t) + c^*(t))\} \\
&= |T_0(t)|^2 + E\{|c(t)|^2\} \\
&= A_0^2 + 2\sigma^2
\end{aligned} \tag{3.37}$$

onde A_0^2 representa a potência da componente especular e $2\sigma^2$ a potência das componentes espalhadas. A razão entre ambas é comumente conhecida como fator K ou fator Rice

$$K = \frac{A_0^2}{2\sigma^2} \tag{3.38}$$

Considerando a independência entre as partes real e imaginária de $c(t)$, pode-se escrever a função densidade de probabilidade conjunta de $u(t)$

$$\begin{aligned}
f_u(x, y) &= \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x - m_R(t))^2 + (y - m_I(t))^2}{2\sigma^2}\right) \\
&= \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2 + A_0^2 - 2(xm_R(t) + ym_I(t))}{2\sigma^2}\right)
\end{aligned} \tag{3.39}$$

Transformando $f_u(x, y)$ para coordenadas polares $f_u(r, \theta)$, com $x = r\cos\theta$ e $y = r\sin\theta$, tem-se

$$f_u(r, \theta) = \frac{r}{2\pi\sigma^2} \exp\left(-\frac{r^2 + A_0^2 - 2rA_0 \cos(\omega_0 t + \phi_0 - \theta)}{2\sigma^2}\right), \quad (r \geq 0, 0 \leq \theta \leq 2\pi) \tag{3.40}$$

Desta forma, a função distribuição de probabilidade do módulo de $u(t)$ é dada por

$$\begin{aligned}
f_{|u|}(r) &= \int_0^{2\pi} f_u(r, \theta) d\theta \\
&= \frac{r}{2\pi\sigma^2} \exp\left(-\frac{r^2 + A_0^2}{2\sigma^2}\right) \int_0^{2\pi} \exp\left(\frac{2rA_0 \cos(\omega_0 t + \phi_0 - \theta)}{2\sigma^2}\right) d\theta
\end{aligned} \tag{3.41}$$

Note que o integrando da equação acima é uma função periódica em θ com período 2π . Como consequência, o termo $(\omega_0 t + \phi_0)$ não tem influência sobre o resultado da integral, a qual pode ser expressa pela função de Bessel modificada de ordem zero

$$\frac{1}{2\pi} \int_0^{2\pi} \exp(a \cos \varphi) d\varphi = I_0(a) \quad (3.42)$$

resultando em

$$f_{|u|}(r) = \frac{r}{\sigma^2} \exp\left(-\frac{r^2 + A_0^2}{2\sigma^2}\right) I_0\left(\frac{rA_0}{\sigma^2}\right), \quad r \geq 0 \quad (3.43)$$

que é conhecida como distribuição de Rice.

Reescrevendo $f_{|u|}(r)$ como função do valor médio quadrático b_R e do fator K , tem-se

$$f_{|u|}(r) = \frac{2r(K+1)}{b_R} \exp\left(-K - \frac{r^2(K+1)}{b_R}\right) I_0\left(2r\sqrt{\frac{K(K+1)}{b_R}}\right), \quad r \geq 0 \quad (3.44)$$

A Figura 3.10 ilustra $f_{|u|}(r)$ para alguns valores de K . Para $K=0$, tem-se uma curva Rayleigh. À medida que K aumenta, a curva se aproxima de uma Gaussiana. Nesse caso há uma menor ocorrência de valores de r próximos ao zero, indicando que a frequência com que os desvanecimentos profundos ocorrem é tão menor quanto maior for a potência da componente especular.

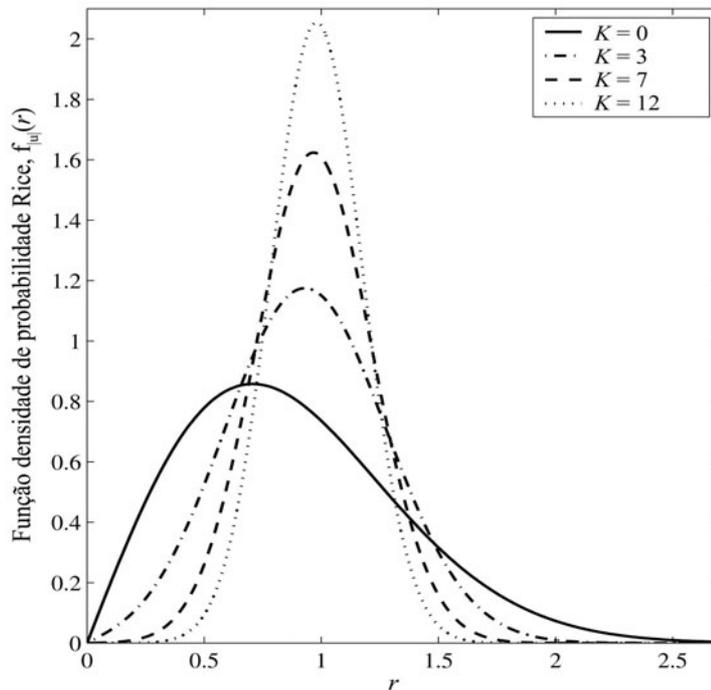


Figura 3.10: Função densidade de probabilidade de Rice para alguns valores de K , com $b_R=1$.

A função densidade de probabilidade de fase de $u(t)$ é dada por [51]

$$\begin{aligned} f_{\angle u}(\theta) &= \int_0^{\infty} f_u(r, \theta) dr = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{A_0^2}{2\sigma^2}\right)} \int_0^{\infty} r e^{-\left(\frac{r^2 - 2rA_0 \cos(\omega_0 t + \phi_0 - \theta)}{2\sigma^2}\right)} dr \\ &= \frac{1}{2\pi} e^{-K} \left(1 + \sqrt{K\pi} \cos(\omega_0 t + \phi_0 - \theta) e^{K \cos^2(\omega_0 t + \phi_0 - \theta)} \left[1 + \operatorname{erf}\left(\sqrt{K} \cos(\omega_0 t + \phi_0 - \theta)\right) \right] \right) \end{aligned} \quad (3.45)$$

onde $\operatorname{erf}(\cdot)$ é a função erro dada por

$$\operatorname{erf}(a) = \frac{2}{\sqrt{\pi}} \int_0^a e^{-t^2} dt \quad (3.46)$$

Para $K=0$ (não há componente especular), $f_{\angle u}(\theta) = 1/(2\pi)$, ou seja, a fase de $u(t)$ é uniformemente distribuída. Para $K \neq 0$, $f_{\angle u}(\theta)$ é uma função do tempo e nesse caso o processo aleatório em questão não é estacionário. Mais especificamente, a curva de densidade de probabilidade sofre um deslocamento cíclico com período igual a $2\pi/\omega_0$ segundos e um deslocamento inicial de ϕ_0 , conforme ilustra a Figura 3.11 para $K=7$, $\phi_0 = \pi/4$, $f_m = 100\text{Hz}$, $\alpha_0 = 0$ e período de deslocamento igual a $2\pi/(2\pi f_m \cos\alpha_0) = 10$ ms. A Figura 3.12 ilustra a curva de densidade de probabilidade em $t=0$ para diferentes valores de K .

As funções de autocorrelação e autocovariância de $u(t)$ são respectivamente

$$\begin{aligned} R_u(t_1, t_2) &= E\{u(t_1)u^*(t_2)\} = E\{(T_0(t_1) + c(t_1))(T_0^*(t_2) + c^*(t_2))\} \\ &= E\{T_0(t_1)T_0^*(t_2) + T_0(t_1)c^*(t_2) + c(t_1)T_0^*(t_2) + c(t_1)c^*(t_2)\} \\ &= T_0(t_1)T_0^*(t_2) + E\{c(t_1)c^*(t_2)\} \\ &= A_0^2 e^{-j\omega_0(t_2-t_1)} + R_c(t_1, t_2) \\ \Rightarrow R_u(\tau) &= A_0^2 e^{-j\omega_0\tau} + R_c(\tau) \end{aligned} \quad (3.47)$$

e

$$\begin{aligned} C_u(t_1, t_2) &= R_u(t_1, t_2) - E\{u(t_1)\}E\{u^*(t_2)\} \\ &= R_u(t_1, t_2) - A_0^2 e^{-j\omega_0(t_2-t_1)} \\ &= R_c(t_1, t_2) \\ \Rightarrow C_u(\tau) &= R_c(\tau) \end{aligned} \quad (3.48)$$

onde $R_c(\tau) = 2\sigma^2 J_0(2\pi f_m \tau)$.

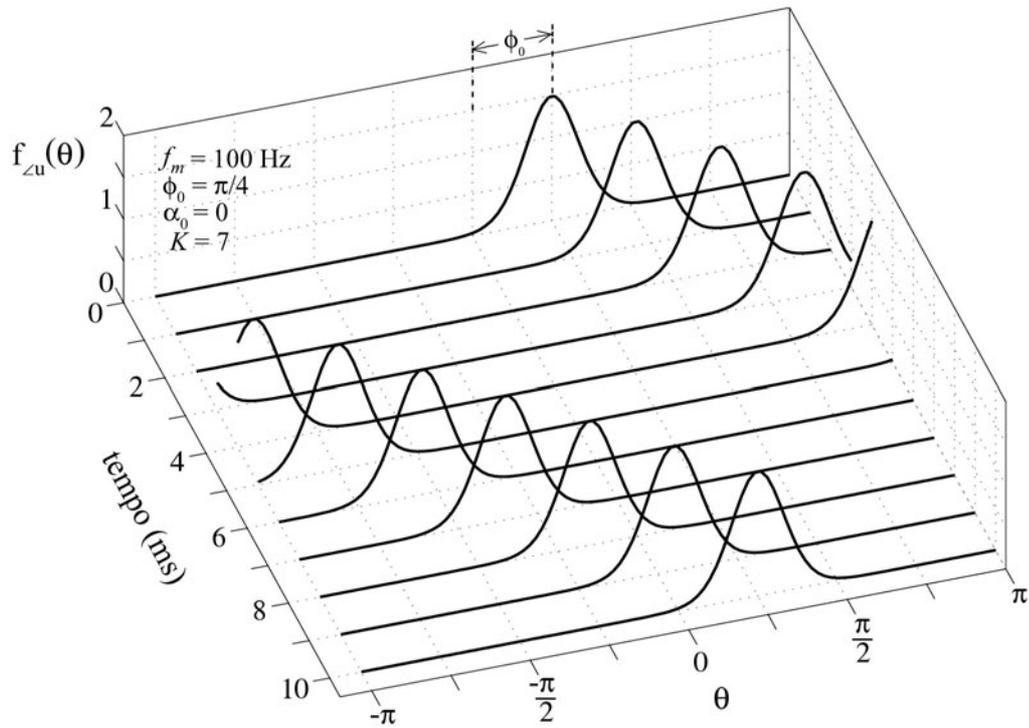


Figura 3.11: Função densidade de probabilidade da fase de $u(t)$.

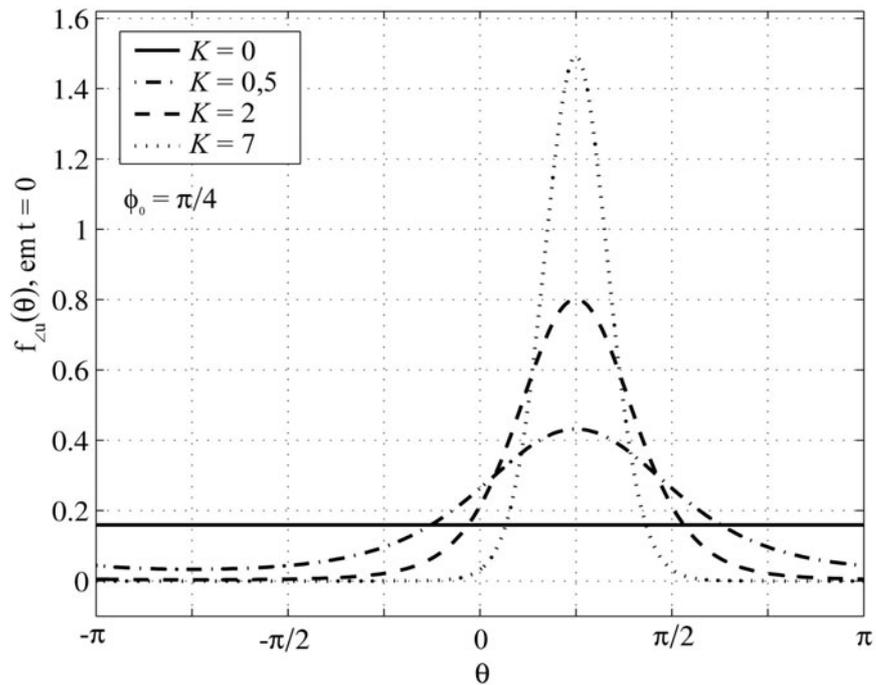


Figura 3.12: Função densidade de probabilidade da fase de $u(t)$ em $t = 0$.

Um modelo simplificado de canal com desvanecimento Rice assume que a componente especular é não variante no tempo [47], ou seja,

$$\begin{aligned} T_0 &= m_R + jm_I = A_0 e^{j\phi_0} \\ \Rightarrow m_R &= A_0 \cos \phi_0 \quad \text{e} \quad m_I = A_0 \sin \phi_0 \\ \Rightarrow A_0^2 &= m_R^2 + m_I^2 \end{aligned} \quad (3.49)$$

resultando em uma média constante no tempo

$$E\{u(t)\} = m_R + jm_I, \quad (3.50)$$

uma função de autocorrelação real

$$R_u(\tau) = A_0^2 + R_c(\tau) \quad (3.51)$$

e uma densidade de probabilidade de fase independente do tempo

$$f_{\angle u}(\theta) = \frac{1}{2\pi} e^{-K} \left(1 + \sqrt{K\pi} \cos(\phi_0 - \theta) e^{K \cos^2(\phi_0 - \theta)} \left[1 + \operatorname{erf} \left(\sqrt{K} \cos(\phi_0 - \theta) \right) \right] \right), \quad (3.52)$$

caracterizando o processo como estacionário no sentido amplo. Note que o valor médio quadrático, o fator K , a densidade de probabilidade de módulo e a função de autocovariância não sofrem alterações.

Assumir a hipótese em (3.49) implica assumir $\alpha_0 = \pm\pi/2 \Rightarrow \omega_0 = 0$, que pode representar uma situação onde haja linha de visada na transmissão e o móvel esteja percorrendo uma trajetória perpendicular ao raio da célula, ou situações com transmissão sem LoS onde a componente especular, após sofrer reflexão, incide sobre o móvel com ângulo perpendicular à sua trajetória.

3.3 CANAL DE COMUNICAÇÃO COM DESVANECIMENTO NAKAGAMI

Em 1943, Minoru Nakagami [52] deduziu (por meio de experimentos sobre desvanecimento rápido em propagação HF de longa distância) uma expressão para função densidade de probabilidade da amplitude de um sinal sujeito ao desvanecimento. A m -distribuição (como foi chamada pelo autor; hoje também conhecida como Nakagami- m) engloba as distribuições Rayleigh e Gaussiana

unilateral e pode ser aproximada para uma distribuição Rice e Log-normal [53].

Medidas experimentais têm mostrado que sob certas condições, a distribuição Nakagami- m pode representar melhor o conjunto de dados coletados [53],[54]. Além disso, essa distribuição pode modelar desvanecimentos sob condições que podem ser mais ou menos severas que os desvanecimentos Rayleigh. Comparada à distribuição Rice, a Nakagami- m oferece uma aproximação conveniente do ponto de vista de manuseio analítico da expressão, uma vez que esta não contém a função de Bessel.

A m -distribuição é definida por [52]

$$f_x(x) = \frac{2m^m x^{2m-1}}{\Gamma(m)\Omega^m} \exp\left\{-\frac{mx^2}{\Omega}\right\}, \quad m \geq \frac{1}{2}, \quad \Omega > 0$$

onde $\Omega = E\{x^2\}$ e $\Gamma(m)$ é a função Gama definida por [43]

$$\Gamma(m) = \int_0^{\infty} y^{m-1} e^{-y} dy, \quad m > 0$$

Quando $m = 1/2$, $f_x(x)$ vem a ser uma distribuição Gaussiana unilateral; quando $m = 1$, $f_x(x)$ vem a ser uma distribuição Rayleigh. Uma aproximação da distribuição log-normal pode ser obtida por meio de $f_x(x)$ para valores elevados de m , sendo x restrito ao domínio $\sqrt{\Omega/e} \leq x \leq \sqrt{\Omega e}$ [54]. Uma aproximação da distribuição Rice pode ser obtida quando $m > 1$ para as seguintes relações entre os parâmetros Rice e m [52]

$$K = \frac{\sqrt{m^2 - m}}{m - \sqrt{m^2 - m}} \quad \text{e} \quad m = \frac{(K-1)^2}{(2K-1)}$$

Valores de m na faixa $1/2 \leq m < 1$ caracterizam desvanecimentos mais severos que os desvanecimentos Rayleigh. Já para $m > 1$ o contrário é válido e à medida que m aumenta os desvanecimentos tornam-se mais brandos. Por essa razão o parâmetro m tem sido chamado de figura de desvanecimento [55].

Em [56], foi proposto um modelo matemático para o desvanecimento Nakagami que é válido para $m = [1/2, 1, 2/3, 2, 5/3, \dots]$, sendo deduzidas suas propriedades estatísticas.

A m -distribuição é uma solução aproximada para o problema geral da distribuição de amplitude da soma de vetores aleatórios. As distribuições Rayleigh e Rice são soluções particulares desse problema. Vários trabalhos têm sido publicados com o objetivo de encontrar uma solução geral para o problema [57]- [60]. A distribuição $\eta-\mu$, apresentada em [57], inclui como caso especial as distribuições Rayleigh, Gaussiana unilateral e Nakagami. As distribuições Rice e log-normal pode ser aproximadas pela distribuição $\eta-\mu$. Já a distribuição $\kappa-\mu$ [58] inclui como caso especial as distribuições Rayleigh, Rice, Gaussiana unilateral e Nakagami- m . A distribuição log-normal pode ser aproximada pela distribuição $\kappa-\mu$. Apresentada em [59], a distribuição $\lambda-\mu$ inclui como caso especial as distribuições Rayleigh, Hoyt, Gaussiana unilateral e Nakagami- m , sendo que a distribuição log-normal pode ser aproximada. Finalmente, a distribuição Simétrica $\eta-\mu$ [60] inclui como caso especial as distribuições Rayleigh, Rice, Gaussiana unilateral, Nakagami- q e Hoyt.

3.4 MODELAGEM COMPUTACIONAL DE CANAL COM DESVANECIMENTO

RAYLEIGH

Utilizando um gerador de números aleatórios Rayleigh para módulo e outro uniforme para fase, pode-se gerar uma componente multipercurso Rayleigh. Trata-se de um método simples e direto para geração de coeficientes de transmissão. Porém, se os geradores forem sem memória (sem correlação entre uma amostra e a subsequente) ocorrerão mudanças bruscas na envoltória entre uma amostra e a sua subsequente (podendo ser da ordem de 40 dB), o que não ocorre em um canal real. Nesse caso, a função de autocorrelação será um impulso na origem e a DEP será plana na faixa de frequência considerada.

Para correlacionar as amostras aleatórias pode-se utilizar um filtro na saída do gerador de números aleatórios, com frequência de corte igual ao máximo deslocamento Doppler, como ilustra a Figura 3.13. Para que resultados satisfatórios sejam obtidos com a filtragem no domínio do tempo (resposta impulsiva se aproximando de uma função de Bessel) é necessário utilizar filtros de ordem elevada, o que incrementa o esforço computacional do simulador [42]. A filtragem no

domínio da frequência é uma alternativa mais atrativa por exigir baixo esforço computacional, além de possibilitar a escolha exata da função de transferência do filtro. Esse é o princípio básico do modelo de Smith [6] e será comentado nos próximos itens.

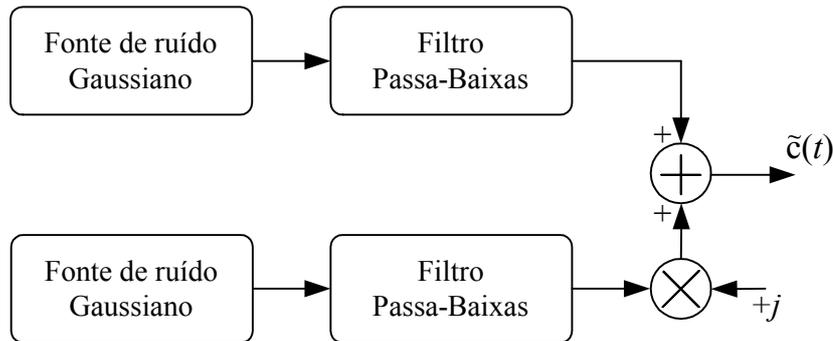


Figura 3.13: Simulador de canal com desvanecimento que utiliza fontes aleatórias filtradas.

Os modelos de Jakes e Smith, assim como suas versões modificadas, serão apresentados nos itens que seguem.

3.4.1 MODELO DE JAKES E SUAS MODIFICAÇÕES

Considere o modelo de propagação por espalhamento de R. H. Clarke [2] ilustrado na Figura 3.1, com sinal recebido definido por (3.9). e com

$$A_n^2 = f_\alpha(\alpha_n) d\alpha$$

representando a potência da n -ésima onda incidente com ângulo α_n e $f_\alpha(\alpha)$ a função densidade de probabilidade de α .

Assumindo que os ângulos de incidência são uniformes no intervalo $[0, 2\pi)$ com $d\alpha = 2\pi/M$ e $\alpha_n = \frac{2\pi n}{M}$, para $n = 1, 2, \dots, M$, conforme pode ser visto na Figura 3.14 para $M=14$, então $A_n^2 = \frac{1}{M}$. Assim, considerando $E_0=1$, os coeficientes de transmissão são dados por

$$T(t) = \frac{1}{\sqrt{M}} \sum_{n=1}^M e^{j(\omega_n t + \phi_n)} \quad (3.53)$$

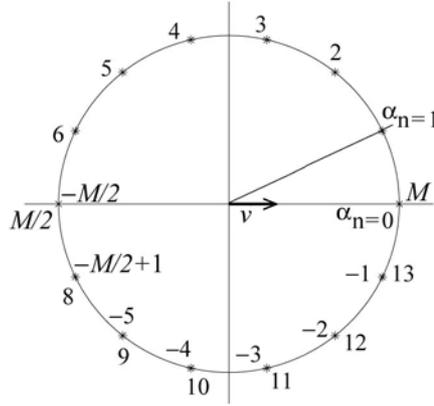


Figura 3.14: Distribuição de ângulo de azimute adotada por Jakes.

Assumindo $M/2$ ser um número inteiro positivo e ímpar e observando que $\omega_n = \omega_{-n}$, pode-se escrever (3.53) para n variando de $-M/2 + 1$ a $M/2$ (ver Figura 3.14)

$$\begin{aligned} T(t) &= \frac{1}{\sqrt{M}} \left(\sum_{n=-M/2+1}^0 e^{j(\omega_n t + \phi_n)} + \sum_{n=1}^{M/2} e^{j(\omega_n t + \phi_n)} \right) \\ &= \frac{1}{\sqrt{M}} \left(\sum_{n=1}^{M/2-1} e^{j(\omega_n t + \phi_{-n})} + e^{j(\omega_0 t + \phi_0)} + \sum_{n=1}^{M/2-1} e^{j(\omega_n t + \phi_n)} + e^{j(\omega_{M/2} t + \phi_{M/2})} \right) \\ &= \frac{1}{\sqrt{M}} \left(\sum_{n=1}^{M/2-1} \left(e^{j(\omega_n t + \phi_{-n})} + e^{j(\omega_n t + \phi_n)} \right) + e^{j(\omega_0 t + \phi_0)} + e^{-j(\omega_{M/2} t - \phi_{M/2})} \right) \end{aligned}$$

onde $\omega_m = 2\pi f_m$.

Nota-se na primeira e segunda exponencial que há uma sobreposição de frequências. Para retirar esta sobreposição e diminuir assim o número de osciladores, foi adotado apenas o primeiro e o terceiro quadrantes da Figura 3.14, resultando em

$$T(t) = \frac{1}{\sqrt{M/2}} \left(\sum_{n=1}^{M_0} \left(e^{-j(\omega_n t - \phi_{-n})} + e^{j(\omega_n t + \phi_n)} \right) + e^{j(\omega_0 t + \phi_0)} + e^{-j(\omega_{M/2} t - \phi_{M/2})} \right) \quad (3.54)$$

onde $M_0 = \frac{1}{2} \left(\frac{M}{2} - 1 \right)$ e $\phi_{-i} = \phi_{-M/2+i}$. Aplicando-se o TLC em (3.54), pode-se considerar $T(t)$ aproximadamente um processo Gaussiano complexo [4].

Para propósitos de implementação, a equação (3.54) é escrita nas suas componentes real e imaginária, respectivamente, porém agora considerando a amplitude de todas as componentes igual a 1 exceto a componente com frequência ω_m , cuja a amplitude considerada é $1/\sqrt{2}$ (para providenciar simetria de potência em cada quadrante), resultando nas componentes

$$T_c(t) = 2 \sum_{n=1}^{M_0} \cos(\omega_n t) \cos(\beta_n) + \sqrt{2} \cos(\omega_m t) \cos(\varphi) \quad (3.55)$$

$$T_s(t) = 2 \sum_{n=1}^{M_0} \cos(\omega_n t) \text{sen}(\beta_n) + \sqrt{2} \cos(\omega_m t) \text{sen}(\varphi) \quad (3.56)$$

onde:

- $\beta_n = \phi_n = \phi_{-n}$
- $\varphi = \phi_0 = \phi_{M/2}$.

Note que apesar da notação idêntica, nesse contexto β_n não representa o ângulo de elevação (modelo de Aulin), mas sim uma composição das fases iniciais de cada oscilador no modelo de Jakes.

As relações (3.55) e (3.56) definem o simulador de canal de Jakes, com M_0 osciladores de frequências ω_n e um oscilador com frequência ω_m . A Figura 3.15 ilustra um diagrama de blocos do simulador.

Finalmente, de (3.8) ou da Figura 3.15, o sinal recebido pode ser reescrito por

$$\begin{aligned} r(t) &= T_c(t) \cos(\omega_c t) - T_s(t) \text{sen}(\omega_c t) \\ &= \sqrt{T_c(t)^2 + T_s(t)^2} \cos\left(\omega_c t + \arctan\left(\frac{T_s(t)}{T_c(t)}\right)\right) \end{aligned}$$

Esta equação mostra que o canal “modula” o sinal enviado em amplitude e fase por um processo aleatório passa-baixas com largura de banda ω_m e densidades de probabilidade Rayleigh para a amplitude e uniforme para fase.

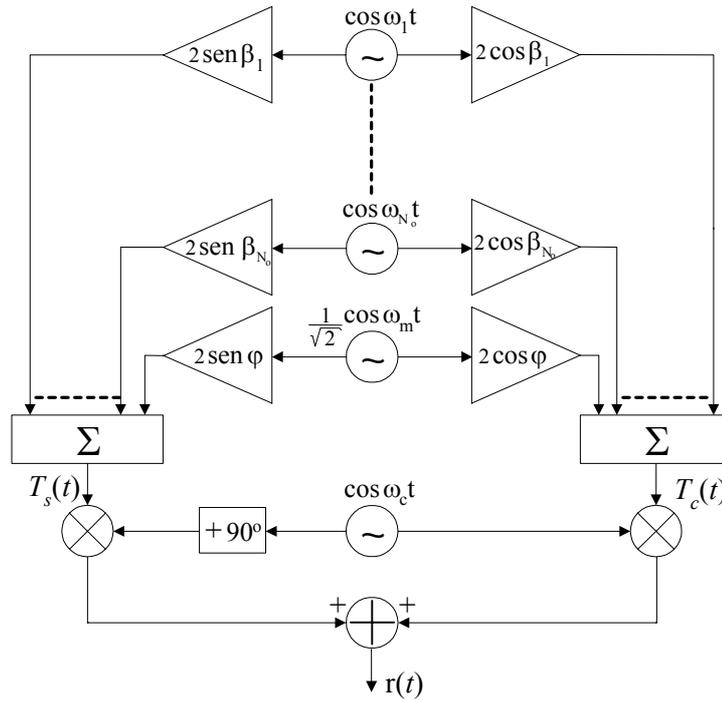


Figura 3.15: Diagrama de blocos do simulador de Jakes.

Para que $T(t)$ seja uniforme de zero a 2π , $T_c(t)$ e $T_s(t)$, além de serem Gaussianos e terem valor médio igual a zero (como pode ser verificado em (3.55) e (3.56)), devem ter aproximadamente a mesma variância e covariância zero. Isto pode ser alcançado escolhendo φ e β_n convenientemente para que $\langle T_c(t)^2 \rangle \approx \langle T_s(t)^2 \rangle$ e $\langle T_c(t)T_s(t) \rangle \approx 0$, onde $\langle \cdot \rangle$ é o operador média temporal definido em (A.6). Escolhendo $\varphi=0$ e $\beta_n = \pi n / M_0$, tem-se $\langle T_s(t)^2 \rangle = M_0$, $\langle T_c(t)^2 \rangle = M_0 + 1$ e $\langle T_c(t)T_s(t) \rangle = 0$, conforme desejado.

A Figura 3.16 ilustra as densidades de probabilidade de $T(t)$ obtidas por simulação (veja Apêndice D, algoritmo “jakes_flat_original”) e as respectivas densidades teóricas, para uma simulação com 10^5 pontos e 16 osciladores, confirmando que as densidades Rayleigh e uniforme realmente podem ser alcançadas através de (3.55) e (3.56).

A autocorrelação normalizada para 8 e 16 osciladores, teórica e obtida por simulação, está ilustrada na Figura 3.17. Note que há uma tendência de divergência entre as curvas teóricas e simuladas com o aumento de $f_m \tau$, o que pode ser

melhorado com o aumento do número de osciladores.

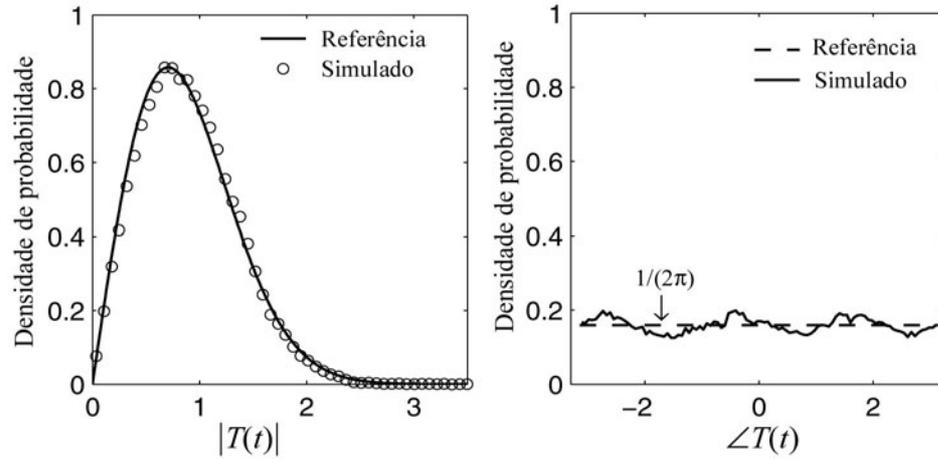


Figura 3.16: Densidades de probabilidade de módulo e fase do modelo de Jakes.

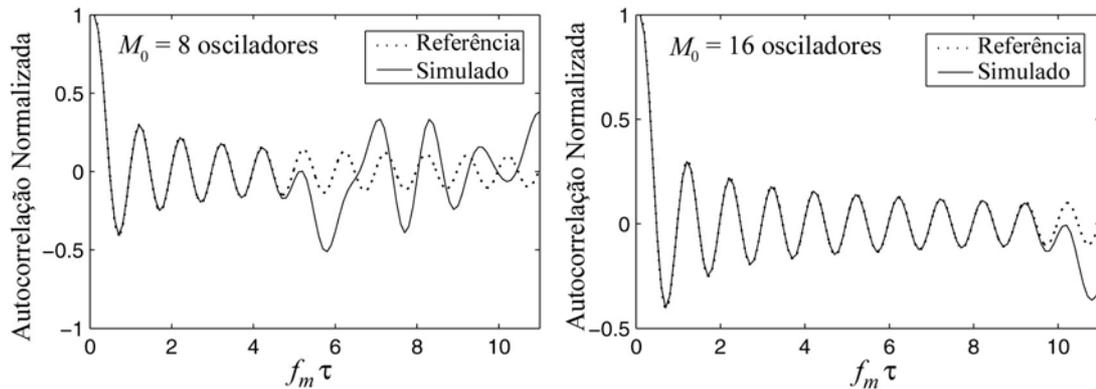


Figura 3.17: Autocorrelação normalizada obtida a partir do modelo de Jakes para 8 e 16 osciladores.

Após as hipóteses e simplificações adotadas por Jakes, verifica-se que as variáveis A_n , α_n e ϕ_n , que de início eram aleatórias passaram a ser determinísticas e conseqüentemente o modelo passou a ser determinístico.

As diversas propostas de melhoria para o modelo de Jakes têm como principal motivação a redução do número de osciladores utilizados visando diminuir o esforço computacional exigido, enquanto propriedades estatísticas corretas são obtidas.

3.4.1.1 MODIFICAÇÃO SEGUNDO DENT

O modelo de Jakes, na forma originalmente proposta, apresenta dificuldades para gerar múltiplas formas de onda não correlacionadas. Na tentativa de solucionar esse problema, Dent em [7] propôs uma alteração na modelagem dos ângulos de chegada, assim como o uso das seqüências (ou palavras-código) ortogonais de Walsh-Hadamard (WH) para ponderar cada oscilador antes da soma. Com esta modificação o autor obteve valores de correlação (entre as formas de onda) da ordem de 10^{-5} , em $\tau=0$, ou seja, formas de onda não correlacionadas. Por esta razão, esse modelo tem sido bem aceito no meio científico, sendo utilizado em diversos trabalhos [42],[61].

A matriz \mathbf{H} de Hadamard com dimensão $L \times L$ pode ser gerada pela seguinte recursão

$$\mathbf{H}_L \triangleq \begin{bmatrix} \mathbf{H}_{L/2} & \mathbf{H}_{L/2} \\ \mathbf{H}_{L/2} & -\mathbf{H}_{L/2} \end{bmatrix}, \quad \text{para } L = 2^l \text{ e } l = 0, 1, 2, \dots \quad (3.57)$$

onde $\mathbf{H}_1 = 1$. Cada linha da matriz \mathbf{H} define uma palavra-código WH.

No modelo de Dent, o ângulo de chegada recebeu um deslocamento de valor π/M , evitando que esse ângulo assumisse os valores 0 e $-\pi$ (veja Figura 3.14) e assim possibilitando simetria perfeita entre quadrantes. Com esta modificação, o ângulo de chegada passou a ser

$$\alpha_n = 2\pi(n - 0,5)/M \quad (3.58)$$

e o número de osciladores necessários para gerar os coeficientes de transmissão sem redundância de frequência Doppler passou a ser $M_0 = M/4$.

Essas modificações levaram ao seguinte modelo [7]

$$T_k(t) = \sqrt{\frac{2}{M_0}} \sum_{n=1}^{M_0} b_k^{M_0} [n] e^{j\beta_n} \cos(\omega_n t + \phi_{k,n}) \quad (3.59)$$

onde:

- $T_k(t)$ = k -ésima componente multipercurso gerada pelo modelo;
- M_0 = número final de osciladores; deve ser potência de dois;

- $M = 4M_0$ é o número inicial de osciladores (utilizado no cálculo de α_n);
- $b_k^{M_0} [n]$ = seqüência em n que representa a k -ésima linha da matriz de Hadamard de tamanho M_0 , ou seja, é a k -ésima palavra-código WH;
- $\beta_n = \pi n / M_0$;
- $\omega_n = 2\pi f_m \cos \alpha_n$;
- $\phi_{k,n}$ = fase inicial (assumida ser aleatória) do n -ésimo oscilador pertencente a k -ésima componente multipercurso.

Novamente, apesar da notação idêntica, nesse contexto β_n não representa o ângulo de elevação (modelo de Aulin), mas sim um ângulo de fase [7].

As médias estatísticas e temporais para esse modelo foram calculadas neste trabalho, no Apêndice B.

- Médias estatísticas:

$$E\{T_k(t)\} = 0 \quad (3.60.a)$$

$$g_{R_T}(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \cos^2 \beta_n \cos(\omega_n \tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \cos^2 \left(\frac{\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right) \quad (3.60.b)$$

$$g_{I_T}(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \sin^2 \beta_n \cos(\omega_n \tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \sin^2 \left(\frac{\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right) \quad (3.60.c)$$

$$h_T(\tau) = \frac{1}{2M_0} \sum_{n=1}^{M_0} \sin(2\beta_n) \cos(\omega_n \tau) = \frac{1}{2M_0} \sum_{n=1}^{M_0} \sin \left(\frac{2\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right) \quad (3.60.d)$$

$$R_T(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \cos(\omega_n \tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right) \quad (3.60.e)$$

- Médias temporais: conforme calculado no Apêndice B, de (B.38) a (B.42), as médias temporais desse modelo são iguais às médias estatísticas. Conseqüentemente, o modelo de Dent é ergódico, além de ser WSS.

A Figura 3.18 ilustra as curvas (3.60.d) e (3.60.e) para 8, 16 e 32 osciladores. Observa-se que a faixa de atrasos onde as curvas de autocorrelação e referência são

coincidentes (gráficos da esquerda) aumenta com o número de osciladores. Já com relação aos gráficos da direita pode-se afirmar que as partes real e imaginária do modelo são não correlacionadas apenas para atraso igual a zero.

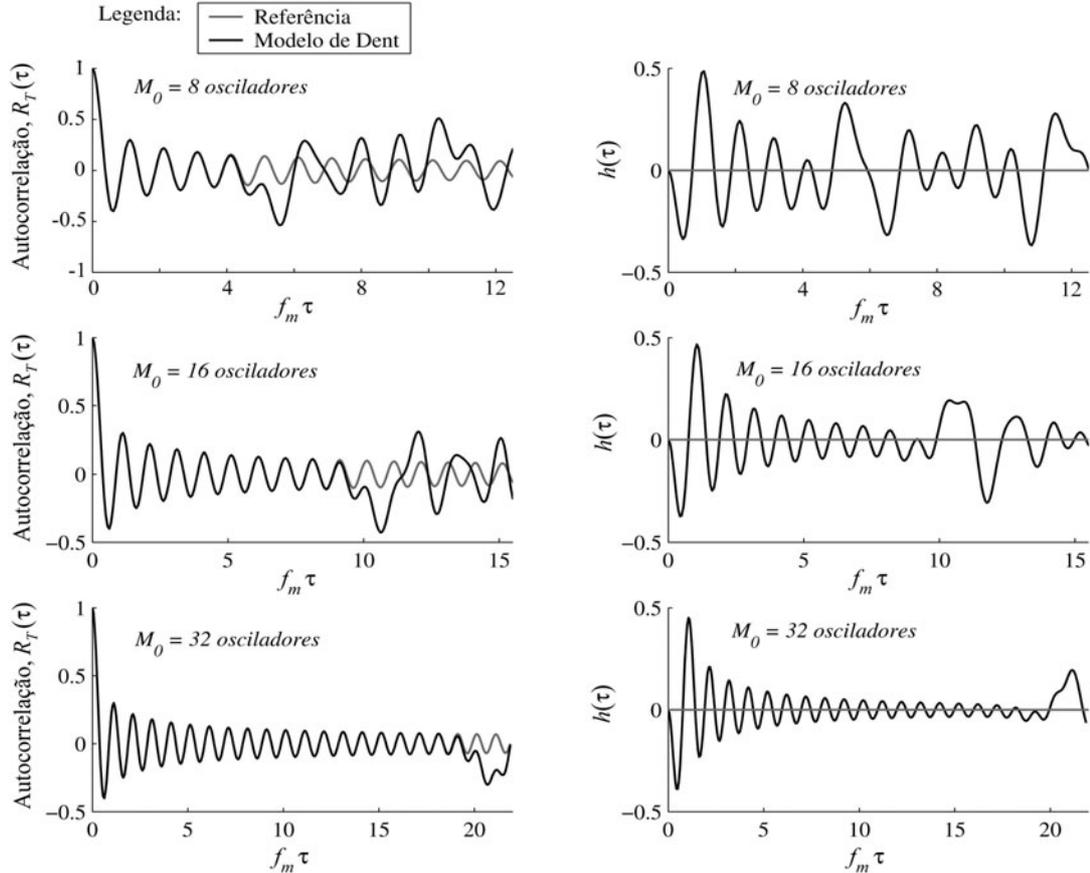


Figura 3.18: Função de autocorrelação e correlação cruzada entre as partes real e imaginária no modelo de Dent. Para curvas de referência veja (3.14), modelo de Clarke.

De (B.43), tem-se a covariância temporal entre duas funções amostras desse modelo

$$\bar{C}_{T_k T_z}(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} b_k^{M_0} [n] b_z^{M_0} [n] \cos(\omega_n \tau + \phi_{z,n} - \phi_{k,n}) \quad (3.61)$$

Observa-se que a covariância temporal não depende do número de amostras, mas é inversamente proporcional ao número de osciladores. Observa-se ainda que não é vantajoso utilizar para cada componente multipercurso um conjunto diferente de fases iniciais, pois pode haver uma correlação elevada entre as componentes

multipercursos em $\tau = 0$, a menos que seja utilizado um número elevado de osciladores, o que pode levar a um esforço computacional elevado. Assim, fazendo $\phi_{z,n} = \phi_{k,n}$ em (3.61), a covariância temporal vem a ser

$$\bar{C}_{T_k T_z}(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} b_k^{M_0}[n] b_z^{M_0}[n] \cos(\omega_n \tau) \quad (3.62)$$

Observando que as seqüências WH são ortogonais, tem-se

$$\bar{C}_{T_k T_z}(0) = 0 \quad (3.63)$$

que é o objetivo inicial do trabalho de Dent. Adotar a hipótese $\phi_{z,n} = \phi_{k,n}$ não altera as médias estatísticas em (3.60).

Finalmente, o modelo fica então definido como

$$T_k(t) = \sqrt{\frac{2}{M_0}} \sum_{n=1}^{M_0} b_k^{M_0}[n] e^{j\beta_n} \cos(\omega_n t + \phi_n) \quad (3.64)$$

Observe que agora, há apenas uma realização do conjunto $\{\phi_n\}$, a qual deve ser utilizada na geração de qualquer função amostra. Assim, o que diferencia uma função amostra de outra é apenas a palavra-código WH. Conseqüentemente, (3.64) fornece um conjunto de M_0 funções amostras com covariância temporal dada por (3.62). Caso seja necessário gerar mais que M_0 funções amostras deve-se fazer outra realização para $\{\phi_n\}$, levando a outro conjunto de funções amostras. Porém, a covariância entre funções amostras de conjuntos diferentes é dada por (3.61).

A Figura 3.19 ilustra algumas curvas de covariância da equação (3.62), onde $M_0 = 16$. Note que, com exceção do ponto $\tau = 0$, os valores de correlação são fortemente dependentes de qual palavra-código WH foi utilizada. Finalmente, na Figura 3.20 pode-se verificar algumas curvas provenientes da equação (3.61), ilustrando a covariância entre funções amostras de conjuntos diferentes. Note que as palavras-código WH utilizadas são as mesmas da Figura 3.19, gráfico superior. Como pode ser observado, ocorrem valores elevados de correlação independentemente do valor de τ , justificando a hipótese adotada para se obter (3.62).

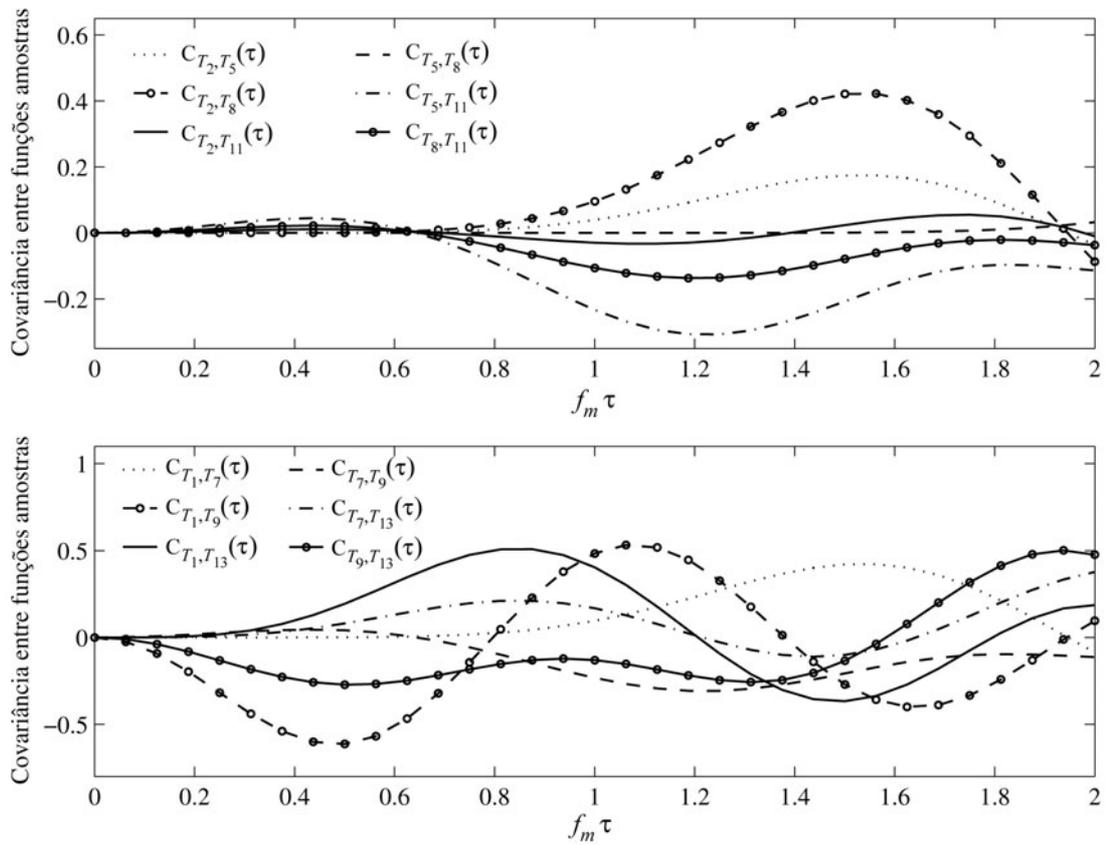


Figura 3.19: Covariância temporal entre funções amostras no modelo de Dent. $M_0 = 16$, $f_m = 100$ Hz e $T_s = 625$ μ s.

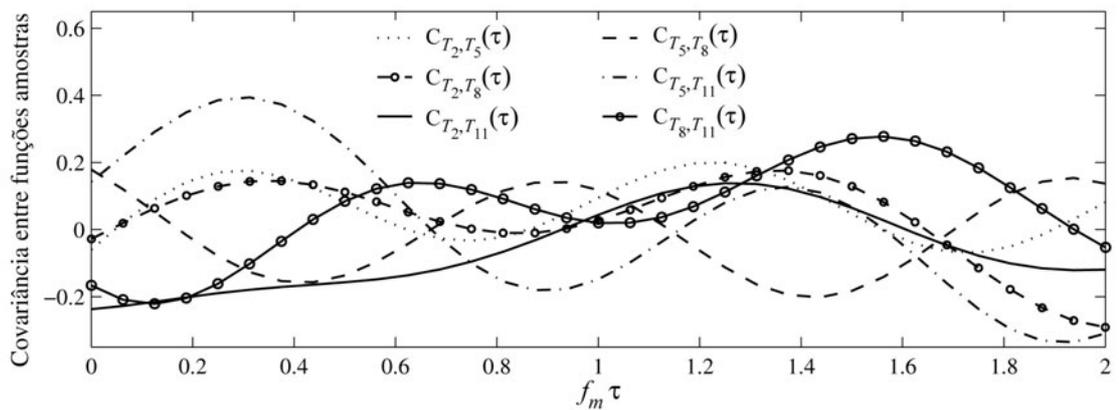


Figura 3.20: Covariância temporal entre funções amostras de conjuntos diferentes. $M_0 = 16$, $f_m = 100$ Hz e $T_s = 625$ μ s.

3.4.1.2 MODIFICAÇÃO SEGUNDO ZHENG

Com a recente modificação apresentada por Zheng [16], o modelo de Jakes passou a

ter médias estatísticas corretas. O autor devolve ao modelo a aleatoriedade retirada por Jakes ao fazer de A_n (ganho de percurso), α_n (ângulo de chegada) e ϕ_n (fase inicial) variáveis aleatórias.

Os coeficientes de transmissão são modelados por

$$x(t) = x_R(t) + jx_I(t) = \sqrt{2} \sum_{n=1}^M A_n \cos(\omega_m t \cos \alpha_n + \phi) \quad (3.65.a)$$

$$x_R(t) = \sqrt{\frac{2}{M}} \sum_{n=1}^M \cos(\psi_n) \cos(\omega_m t \cos \alpha_n + \phi) \quad (3.65.b)$$

$$x_I(t) = \sqrt{\frac{2}{M}} \sum_{n=1}^M \sin(\psi_n) \cos(\omega_m t \cos \alpha_n + \phi) \quad (3.65.c)$$

onde $\alpha_n = \frac{2\pi n - \pi + \theta}{4M}$, $A_n = \frac{e^{j\psi_n}}{\sqrt{M}}$ e $\{\theta, \phi, \psi_n\}$ são variáveis aleatórias estatisticamente independentes e uniformemente distribuídas sobre o intervalo $[0, 2\pi)$ para qualquer n .

O processo gerado a partir de (3.65) reproduz todas as propriedades apresentadas em (3.14), independentemente do número de osciladores M , o qual foi assumido em [16] ser igual a 8. Esta vantagem não se verifica para as funções densidades de probabilidade do modelo, pois aplicando o TLC em (3.65) nota-se que esse processo tende a ser Gaussiano complexo somente para valores elevados de M . Além disso, o modelo matemático de propagação por espalhamento de Clarke, amplamente aceito no meio científico como modelo teórico de canal com desvanecimento, é ergódico (conforme verificado no início deste capítulo). Assim, em modelos computacionais de canal com desvanecimento deve-se avaliar, além das médias estatísticas, as médias temporais. Desta forma, as médias temporais para o modelo Jakes modificado foram calculadas aqui neste trabalho (veja APÊNDICE B para detalhes) e são dadas por

$$\langle (x(t)) \rangle = 0 \quad \Rightarrow \quad \langle (x_R(t)) \rangle = 0 = \langle (x_I(t)) \rangle \quad (3.66.a)$$

$$\langle |x(t)|^2 \rangle = 1 \quad \Rightarrow \quad \tilde{\sigma}^2 = \frac{1}{2} \quad (3.66.b)$$

$$\tilde{g}_R(\tau) = \langle (x_R(t)x_R(t+\tau)) \rangle = \tilde{\sigma}^2 \frac{2}{M} \sum_{n=1}^M \cos^2(\psi_n) \cos(\omega_m \tau \cos \alpha_n) \quad (3.66.c)$$

$$\tilde{g}_I(\tau) = \langle (x_I(t)x_I(t+\tau)) \rangle = \tilde{\sigma}^2 \frac{2}{M} \sum_{n=1}^M \sin^2(\psi_n) \cos(\omega_m \tau \cos \alpha_n) \quad (3.66.d)$$

$$\tilde{h}(\tau) = \langle (x_R(t)x_I(t+\tau)) \rangle = \tilde{\sigma}^2 \frac{1}{M} \sum_{n=1}^M \sin(2\psi_n) \cos(\omega_m \tau \cos \alpha_n) \quad (3.66.e)$$

$$\tilde{R}_x(\tau) = \langle (x(t)x^*(t+\tau)) \rangle = 2\tilde{\sigma}^2 \frac{1}{M} \sum_{n=1}^M \cos(\omega_m \tau \cos \alpha_n) \quad (3.66.f)$$

onde o símbolo “ $\langle \cdot \rangle$ ” indica média temporal e o símbolo “ \sim ” valor obtido através de cálculo.

Note que para $T \rightarrow \infty$ o valor médio temporal é nulo, independentemente de qual função amostra do processo for utilizada. Logo, para qualquer função amostra o valor médio temporal e a esperança são iguais, indicando que o processo é ergódico em média. Porém, comparando (3.14) e (3.66) verifica-se que: $\tilde{h}(\tau) \neq h(\tau)$ e $\tilde{g}_R(\tau) \neq g(\tau) \neq \tilde{g}_I(\tau)$. Pode-se mostrar (veja equação (B.23)) que para $M \rightarrow \infty$, tem-se $\tilde{R}_x(\tau) = R_x(\tau)$. A Figura 3.21 ilustra o resultado de uma realização possível para as funções em (3.66), tomando como referência as funções em (3.14). Observa-se que quando M assume valores pequenos (nesse caso igual a 8), todas as curvas de funções de correlação temporais divergem das referências. Já para M igual a 64 há uma melhora significativa no resultado, ou seja, as curvas se aproximam mais da referência. Esta é uma característica já apresentada pelo modelo matemático de Clarke, onde idealmente deve-se considerar $M \rightarrow \infty$, ou seja, um número infinito de componentes de onda chegando no receptor. Desta forma, pode-se afirmar que o modelo de Jakes modificado é ergódico (em média e funções de correlação), pois idealmente deve-se ter $M \rightarrow \infty$. Porém, por tratar-se de um modelo computacional, o valor de M deve ser finito. Assim, é mais prudente afirmar que esse modelo de Jakes modificado é ergódico somente para $M \geq M_{\min}$, onde M_{\min} pode ser por exemplo igual a 64, se os resultados da Figura 3.21 puderem ser considerados satisfatórios para a

aplicação desejada.

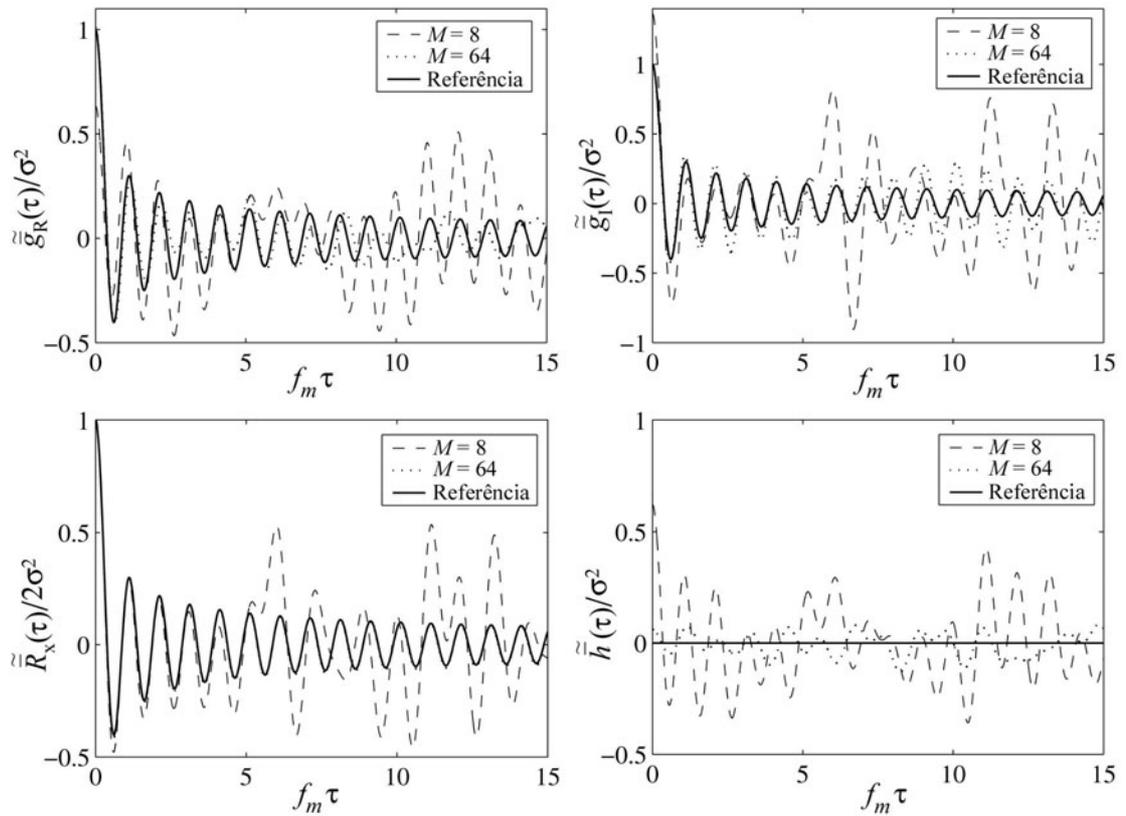


Figura 3.21: Funções de correlação temporal para o modelo Jakes modificado.

3.4.2 MODELO DE SMITH E SUAS MODIFICAÇÕES

Em 1975, John I. Smith [6] apresentou um modelo de simulação de canal com desvanecimento (desvanecimento rápido), que gerava os coeficientes de transmissão com envoltória Rayleigh e fase uniforme, podendo ser implementado em *hardware* (foi implementado em hardware pelo autor para uso em seu laboratório) e *software* (uma rotina em linguagem Fortran foi apresentada em seu trabalho). No primeiro caso, eram utilizadas fontes de ruído Gaussiano que tinham seu espectro formatado pelo espectro de um sinal desvanecido. Na implementação em *software*, as fontes de ruído Gaussiano eram substituídas por geradores de números aleatórios, com a mesma formatação de espectro.

Pode-se fazer uma descrição do modelo de Smith baseada nas informações contidas em uma rotina em linguagem Fortran apresentada em [6] e reproduzida na Figura

3.22. Uma análise detalhada sobre o modelo também pode ser encontrada em [15].

```

SUBROUTINE RAYFDE(FD,X)
C RETURNS 200 RAYLEIGH PHASED ELEMENTS (IN DB) AT 5 MSEC INTERVALS
DIMENSION X(200),A(200),F(100)
PI=3.14159265
DO 17 I=1,200;X(I)=0.;17 Z(I)=0
IR=ITIMEZ(0)
N=200; IM=FD
DO 20 I=2,IM
T=I -1;P=SQRT(1.-(T/FD)**2)
20 F(I)=1./SQRT(P)
IMM=IM+1;P=FLOAT(2.*IM-1);P=FLOAT(IM-10/SQRT(P))
P=FLOAT(IM)*(PI/2.-ATAN(P));F(IMM)=SQRT(P)
C ARRAY F CONTAINS THE FILTER FACTORS
DO 30 I=2,IMM
30 X(I)=F(I)*RNORMS(IR)
DO 40 I=2,IMM
40 Y(I)=-F(I)*RNORMS(IR)
C RNORMS IS A RANDOM NUMBER GENERATOR WITH GAUSSIAN DISTRIBUTION
CALL FFTRAN(N,X,Y)
CALL FACTR(N)
C FFTRAN AND FCTR ARE FAST FOURIER TRANSFORM ROUTINES
DO 50 I=1,200
50 Y(I)=0
DO 60 I=2,IMM
60 Y(I)=F(I)*RNORMS(IR)
DO 70 I=2,IMM
70 Z(I)=-F(I)*RNORMS(IR)
CALL FFTRAN(N,Y,Z)
CALL FACTR(N)
S=0
C TWO INDEPENDENT AND FILTERED NOISE SOURCES ARE COMBINED IN QUADRATURE
DO 80 I=1,200
X(I)=X(I)**2+Y(I)**2
80 S=S+X(I)
S=S/200
Q=10./ALOG(10.)
DO 90 I=1,200
90 X(I)=Q*ALOG(X(I)/S)
C OUTPUT IS THE ARRAY X CONTAINING 200 LEVEL POINTS (IN dB NORMALIZED TO A 0 dB MEAN).
RETURN
END

```

Figura 3.22: Algoritmo em linguagem Fortran sugerido por Smith.

FONTE: SMITH [6], 1975, p. 39.

Considere o diagrama de blocos do modelo ilustrado na Figura 3.23. Dois processos aleatórios Gaussianos complexos filtrados no domínio da frequência por um filtro passa-baixas $F[k]$ são gerados. A transformada discreta de Fourier inversa é aplicada em cada processo. As partes reais ($\text{Re}\{\cdot\}$) do resultado da transformada dos

processos (1) e (2) compõem, respectivamente, as partes real e imaginária do resultado final. De acordo com a notação presente na Figura 3.23, para $F[k]$ real, tem-se

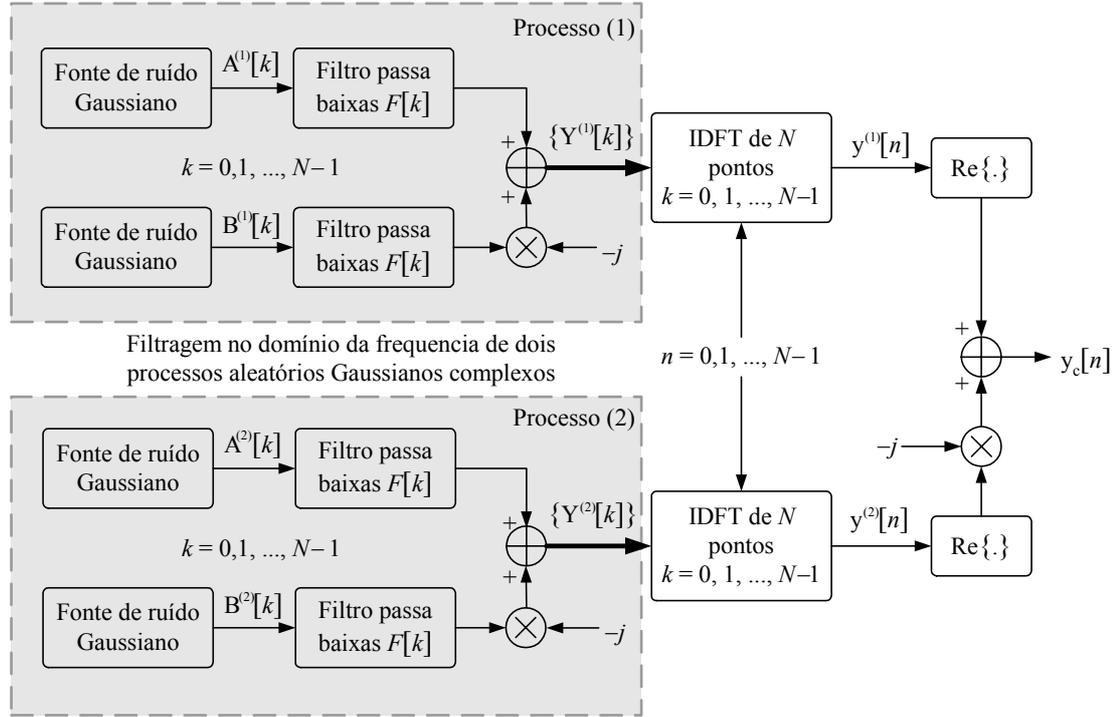


Figura 3.23: Diagrama de blocos do modelo de Smith.

$$Y^{(i)}[k] = F[k] \left(A^{(i)}[k] - jB^{(i)}[k] \right), \quad i = 1, 2. \quad (3.67)$$

$$y^{(i)}[n] = \frac{1}{N} \sum_{k=0}^{N-1} F[k] \left(A^{(i)}[k] - jB^{(i)}[k] \right) e^{j2\pi kn/N}, \quad i = 1, 2. \quad (3.68)$$

$$y_c[n] = \text{Re}\{y^{(1)}[n]\} - j \text{Re}\{y^{(2)}[n]\} \quad (3.69)$$

onde N é o número total de amostras simuladas, $A[k]$ e $B[k]$ são seqüências de variáveis aleatórias Gaussianas independentes, de valor médio igual a zero e mesma variância. A independência entre as variáveis implica

$$E\{A[k]A[z]\} = 0 = E\{B[k]B[z]\}, \quad \forall k \neq z \quad (3.70)$$

e

$$E\{A[k]B[z]\} = 0, \quad \forall k, z \quad (3.71)$$

O filtro $F[k]$ é dado por

$$F[k] = \begin{cases} 0, & k = 0 \\ \sqrt{\frac{1}{\sqrt{1 - \left(\frac{k}{f_m}\right)^2}}}, & k = 1, 2, \dots, f_m - 1 \\ \sqrt{f_m \left(\frac{\pi}{2} - \arctan\left(\frac{f_m - 1}{\sqrt{2f_m - 1}}\right) \right)}, & k = f_m \\ 0, & k = f_m + 1, \dots, N - 1 \end{cases} \quad (3.72)$$

Nota-se que o máximo deslocamento Doppler f_m representa a frequência de corte do filtro e nesse caso (modelo original) deve ser um número inteiro. Pode ser mostrado que a adoção de $F[0]=0$ garante ergodicidade em média para o modelo [15]. Além disso, em [15] há a descrição de um procedimento para se encontrar o valor de $F[k=f_m]$ assumido por Smith em (3.72). Procedimento semelhante será adotado no modelo de canal com desvanecimento proposto neste trabalho.

Verifica-se que em (3.68) há um somatório de variáveis aleatórias Gaussianas independentes, tanto na parte real quanto na imaginária, o que resulta em um processo aleatório Gaussiano complexo. Conseqüentemente, (3.69) também será um processo aleatório Gaussiano complexo, com pdf Rayleigh para o módulo, conforme desejado.

3.4.2.1 MODIFICAÇÃO SEGUNDO YOUNG

A modificação apresentada por Young [15] diminuiu o esforço computacional apresentado pelo modelo, mantendo suas propriedades estatísticas corretas. O diagrama de blocos do modelo modificado pode ser visto na Figura 3.24. Note pelo diagrama que somente o processo (1) do modelo original está sendo utilizado

(compare com a Figura 3.23). Assim, a quantidade de geradores de números aleatórios caiu de 4 para 2 e somente uma IDFT precisa ser calculada.

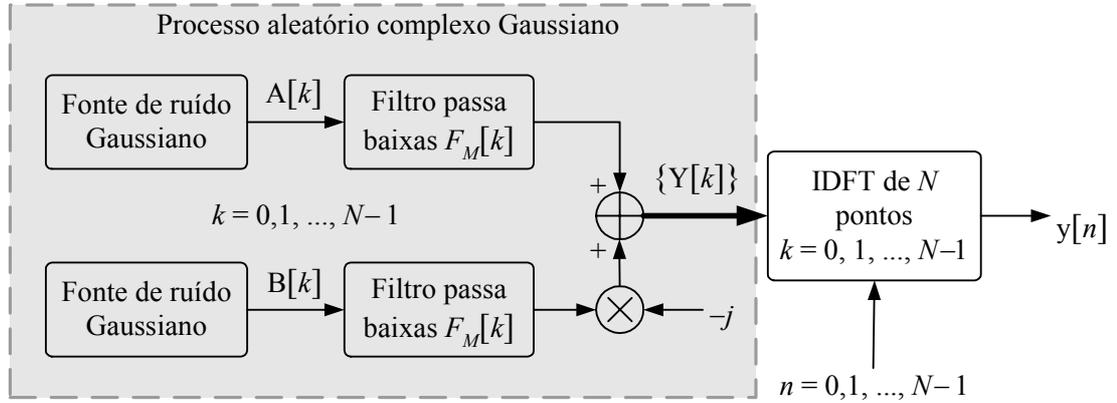


Figura 3.24: Diagrama de blocos do modelo de Smith após a modificação de Young.

O modelo pode então ser definido por

$$y[n] = \frac{1}{N} \sum_{k=0}^{N-1} F_M[k] (A[k] - jB[k]) e^{j2\pi kn/N}, \quad n = 0, 1, \dots, N-1 \quad (3.73)$$

O projeto do filtro foi realizado sob a condição de tornar as propriedades estatísticas em (3.14.d) e (3.14.e) válidas para o processo resultante $y[n]$, o que resultou em

$$F_M[k] = \begin{cases} 0, & k = 0 \\ \sqrt{\frac{1}{2\sqrt{1 - \left(\frac{k f_s}{N f_m}\right)^2}}}, & k = 1, 2, \dots, K_m - 1 \\ \sqrt{\frac{K_m}{2} \left(\frac{\pi}{2} - \arctan\left(\frac{K_m - 1}{\sqrt{2K_m - 1}}\right) \right)}, & k = K_m \\ 0, & k = K_m + 1, \dots, N - K_m - 1 \\ \sqrt{\frac{K_m}{2} \left(\frac{\pi}{2} - \arctan\left(\frac{K_m - 1}{\sqrt{2K_m - 1}}\right) \right)}, & k = N - K_m \\ \sqrt{\frac{1}{2\sqrt{1 - \left(\frac{(N - k) f_s}{N f_m}\right)^2}}}, & k = N - K_m + 1, \dots, N - 1 \end{cases} \quad (3.74)$$

onde f_s é a frequência de amostragem e

$$K_m = \left\lfloor \frac{f_m}{f_s} N \right\rfloor \quad (3.75)$$

onde o operador $\lfloor x \rfloor$, para $x \in \mathfrak{R}$, sendo \mathfrak{R} o conjunto dos números reais, indica o maior inteiro menor ou igual a x . Os pontos $k = 0$ e $k = K_m$ em (3.74) foram definidos da mesma forma que no modelo original de Smith.

Pode ser verificado em [15] que as propriedades estatísticas dos coeficientes de transmissão obtidos por (3.73) utilizando o filtro dado em (3.74) concordam com as propriedades teóricas em (3.14). Além disso, o modelo é ergódico em média e autocorrelação [15].

Finalmente, comparações realizadas em [15] mostraram que o tempo de execução caiu aproximadamente pela metade com a modificação, além de haver economia em memória.

3.5 MODELAGEM COMPUTACIONAL DE CANAL COM DESVANECIMENTO

RICE

Para gerar numericamente os coeficientes de desvanecimento de uma componente multipercurso Rice (dada por (3.36)) deve-se somar uma componente especular aos coeficientes de desvanecimento Rayleigh gerados a partir de um simulador adequado para tal. Assim, os coeficientes discretos de desvanecimento Rice podem ser dados por

$$\tilde{u}[n] = T_0(nT_s) + \tilde{c}[n] = A_0 e^{j(\omega_0 n T_s + \phi_0)} + \tilde{c}[n] \quad (3.76)$$

onde, além dos parâmetros necessários para gerar $\tilde{c}[n]$ (coeficientes de desvanecimento Rayleigh), torna-se necessário conhecer os seguintes parâmetros:

- K : fator Rice que caracteriza o canal a ser simulado;
- b_R : valor médio quadrático da componente multipercurso Rice;

- ϕ_0 : ângulo de fase da componente especular;
- ω_0 : deslocamento Doppler da componente especular.

De (3.37) e (3.38), tem-se

$$A_0 = \sqrt{\frac{K}{1+K}} b_R \quad \text{e} \quad 2\sigma^2 = \frac{1}{1+K} b_R \quad (3.77)$$

Do ponto de vista de simulação é razoável considerar que a componente especular, por possuir maior potência, tenha o menor atraso entre as $M+1$ componentes formadoras da componente multipercurso Rice $u(t)$. Portanto, o atraso τ_0 da componente especular é determinado (igual) pelo atraso τ_u de $u(t)$. Conseqüentemente, a fase ϕ_0 pode ser calculada por

$$\phi_0 = -(\omega_c + \omega_0) \tau_u \quad (3.78)$$

Quando a simulação envolver apenas uma componente multipercurso, pode-se assumir $\tau_u = 0$, pois o atraso nesse caso é apenas uma referência de tempo. O mesmo acontece em uma simulação de canal com várias componentes multipercurso, onde haja uma componente multipercurso Rice e as demais Rayleigh. Nesse caso, a componente multipercurso Rice pode ser tomada como a referência de tempo ($\tau_u = 0$), uma vez que tem potência maior que as componentes multipercurso Rayleigh. Já em uma simulação de canal com várias componentes multipercurso Rice, como foi considerado em [62] por exemplo, é conveniente observar o perfil de atraso-potência do tipo de canal em questão para atribuir valores a τ_u , resultando nos respectivos valores de ϕ_0 de cada componente multipercurso Rice.

Quanto à frequência Doppler ($\omega_0 = 2\pi f_m \cos \alpha_0$) da componente especular, uma vez que α_0 pode assumir qualquer valor entre 0 e 2π , então $\omega_0/(2\pi)$ pode assumir qualquer valor entre $-f_m$ e $+f_m$. Caso o modelo simplificado apresentado em (3.49) seja adotado, assume-se $\omega_0 = 0$.

O fator K tem sido determinado experimentalmente através de medidas da resposta impulsiva do canal. No trabalho realizado em [63], medidas foram coletadas na

cidade de Ottawa, Canadá, a 900 MHz, dentro de um raio de até 30 km, com antena da estação base a 33,5 metros de altura. Quatro tipos de ambientes foram considerados: área aberta, suburbana, urbana com baixa densidade e urbana com média densidade. Nos ambientes em questão, o modelo de canal Rice se mostrou mais apropriado para descrever estatisticamente os dados coletados, indicando a presença de uma componente especular entre transmissor e receptor. A Tabela 3.1 reproduz alguns dos resultados obtidos em [63], os quais foram utilizados para determinar os valores de K .

Tabela 3.1: Parâmetros estimados para a distribuição de Rice.

Ambiente	A_0	σ	K (dB)
Área aberta	0,9615	0,26910	8,0504
Suburbana	0,9514	0,29960	7,0261
Urbana baixa densidade	0,9256	0,36167	5,1519
Urbana média densidade	0,9022	0,40555	3,9349

FONTE: LECOURS [63], 1988, p.210.

Já no trabalho realizado por Bultitude [49], medidas foram coletadas também na cidade de Ottawa (região central), a 910 MHz, com linha de visada, porém com antena da estação base entre 3,7 e 8,2 metros de altura, caracterizando ambiente microcelular. A função distribuição de probabilidade obtida a partir dos dados coletados se ajustou muito bem a uma função distribuição de probabilidade Rice com $K=7$ dB. Em outro experimento realizado pelo mesmo autor e citado em [49], medidas foram coletadas nesse mesmo local, porém com antena da estação base no topo de um edifício de 24 andares (macro célula). Nesse caso, foi verificado que a distribuição Rayleigh representava melhor os dados coletados.

Glazunov, Asplund e Berg [64] realizaram diversas medidas (1,88 GHz de frequência de portadora) de resposta impulsiva complexa (termo-curto) do canal, na cidade de Estocolmo, em ambientes suburbanos e urbanos. As medidas foram realizadas com as antenas da estação base e móvel localizadas a 25 metros de altura e no topo de um furgão, respectivamente e com a distância entre ambas variando entre

150 m e 2,5 km. Os autores se propuseram a testar o ajuste entre as curvas de distribuição de probabilidade (cdf) obtidas por meio das medidas realizadas e cinco curvas teóricas candidatas a representarem os dados. São elas: Rayleigh, Rice, Nakagami, Weibull e Log-normal. Seguindo o critério de Cramer-von-Mises, foi verificado o erro de ajuste para cada distribuição teórica, dado pela integral

$$\varepsilon^2 = \int_{-\infty}^{+\infty} (F_r(r) - F'_r(r))^2 f_r(r) dr, \quad (3.79)$$

onde $F_r(r)$ é a cdf teórica, $F'_r(r)$ a cdf obtida numericamente por meio das medidas e $f_r(r)$ a pdf teórica. Note que esta integral representa um erro quadrático ponderado pela densidade de probabilidade, realçando o erro nas regiões onde os valores são mais prováveis. Os resultados mostraram que em 70% dos casos o melhor ajuste foi obtido com a distribuição Rice.

A relação entre o atraso apresentado por uma componente multipercurso e seu respectivo fator K foi nomeada perfil atraso-desvanecimento (FDP) $K(\tau)$ em [64]. Realizando uma média entre as FDP's encontradas por meio das medidas foi possível modelar o fator K da seguinte forma [64]

$$K_{av}(\tau) = \begin{cases} K_i, & \tau = \tau_i \\ K_f, & \tau > \tau_i \end{cases} \quad (3.80)$$

onde τ_i é o atraso da componente multipercurso de maior potência. Os valores de K_i e K_f estão reproduzidos na Tabela 3.2.

Tabela 3.2: Parâmetros para o FDP médio.

Área onde foi realizada a medida	K_i (dB)	K_f (dB)
Misto de região urbana com suburbana fora dos limites da cidade de Estocolmo	8,129	1,461
Região central da cidade de Estocolmo	7,404	2,553

FONTE: GLAZUNOV [64], 1999, p.110.

3.6 COMPONENTES MULTIPERCURSO COM CORRELAÇÃO PRÉ-DETERMINADA

Em algumas situações de simulação pode haver interesse em gerar formas de ondas (componentes multipercurso) correlacionadas, porém com um grau de correlação pré-determinado. Pode-se citar como exemplo a simulação de um sistema multiportadoras, onde a correlação entre duas componentes multipercurso depende do espaçamento em frequência de suas respectivas subportadoras.

Quando o objetivo for gerar apenas duas componentes multipercurso correlacionadas, pode-se realizar uma combinação linear entre duas formas de onda não correlacionadas, para se obter uma terceira com um grau de correlação específico [42]. Considere a seguinte combinação linear

$$c_3(t) = \sqrt{\frac{2\sigma_3^2}{a^2(2\sigma_1^2) + (1-a)^2(2\sigma_2^2)}} (ac_1(t) + (1-a)c_2(t)), \quad 0 \leq a \leq 1 \quad (3.81)$$

onde a é uma constante real, $2\sigma_1^2 = E\{|c_1(t)|^2\}$, $2\sigma_2^2 = E\{|c_2(t)|^2\}$, $2\sigma_3^2 = E\{|c_3(t)|^2\}$, com $E\{c_1(t)c_2^*(t+\tau)\} = 0$. A correlação cruzada normalizada entre $c_1(t)$ e $c_3(t)$ é dada por

$$\Psi_{1,3}(\tau, a) = \frac{E\{c_1(t)c_3^*(t+\tau)\}}{\sqrt{(2\sigma_1^2)(2\sigma_3^2)}} = \frac{1}{\sqrt{(2\sigma_1^2)(a^2(2\sigma_1^2) + (1-a)^2(2\sigma_2^2))}} aR_1(\tau) \quad (3.82)$$

Note que para a variando de 0 a 1, $\Psi_{1,3}(\tau)$ também varia de 0 a 1, em $\tau=0$. Resolvendo a equação acima para a com $\tau=0$, tem-se

$$a(\Psi_{1,3}) = \frac{K - \sqrt{(2\sigma_1^2)^2(1 - \Psi_{1,3}^2)K}}{K - (2\sigma_1^2)^2(1 - \Psi_{1,3}^2)}, \quad 0 \leq \Psi_{1,3} \leq 1 \quad (3.83)$$

onde $K = \Psi_{1,3}^2(2\sigma_1^2)(2\sigma_2^2)$. A equação (3.83) permite encontrar o valor de a para que a correlação entre $c_1(t)$ e $c_3(t)$, em $\tau=0$, seja $\Psi_{1,3}$. A Figura 3.25 ilustra a relação entre a correlação cruzada normalizada (em $\tau=0$) e o parâmetro a .

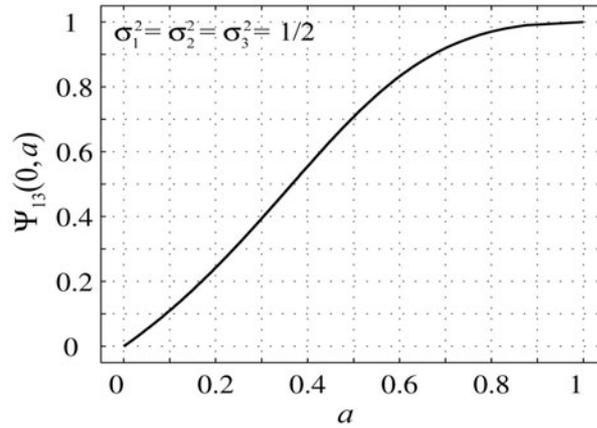


Figura 3.25: Correlação cruzada normalizada em função do parâmetro a .

Considere o caso onde L componentes multipercurso correlacionadas entre si devem ser geradas. Seja $\underline{c}_k[n]^T = [c_k[0], c_k[1], \dots, c_k[N-1]]$ um vetor linha de N variáveis aleatórias gaussianas complexas de média zero e mesma variância σ_k^2 , representando a k -ésima componente multipercurso discreta, onde

$$E\{c_k[n]c_k^*[m]\} = 2\sigma_k^2 J_0(2\pi(m-n)T_s f_m) \quad (3.84)$$

e

$$E\{c_k[n]c_l^*[m]\} = 0, \quad \forall n, m \text{ e } k \neq l. \quad (3.85)$$

Seja também \mathbf{C} uma matriz de dimensão $L \times N$, com linhas compostas pelas componentes multipercurso em questão, ou seja,

$$\mathbf{C} = \begin{bmatrix} \underline{c}_1[n]^T \\ \underline{c}_2[n]^T \\ \vdots \\ \underline{c}_L[n]^T \end{bmatrix} = \begin{bmatrix} c_1[0] & c_1[1] & \cdots & c_1[N-1] \\ c_2[0] & c_2[1] & \cdots & c_2[N-1] \\ \vdots & \vdots & \ddots & \vdots \\ c_L[0] & c_L[1] & \cdots & c_L[N-1] \end{bmatrix} = [\underline{\mathbf{g}}[0] \quad \underline{\mathbf{g}}[1] \quad \cdots \quad \underline{\mathbf{g}}[N-1]]. \quad (3.86)$$

onde $\underline{\mathbf{g}}[n]^T = [c_1[n], c_2[n], \dots, c_L[n]]$, $n = 0, 1, \dots, N-1$.

Um método para a geração de L componentes multipercurso correlacionadas entre si, apresentado em [65], consiste em encontrar uma matriz de transformação \mathbf{A} de dimensão $L \times L$, que ao ser multiplicada pelo vetor de variáveis aleatórias

independentes $\underline{\mathbf{g}}[n]$ resulte em um novo vetor de variáveis aleatórias correlacionadas $\underline{\mathbf{h}}[n]$

$$\begin{aligned}\underline{\mathbf{h}}[n] &= \mathbf{A}\underline{\mathbf{g}}[n] \\ &= [h_1[n], h_2[n], \dots, h_L[n]]^T\end{aligned}\quad (3.87)$$

A matriz de correlação de $\underline{\mathbf{g}}[n]$ é dada por

$$E\{\underline{\mathbf{g}}[n]\underline{\mathbf{g}}[n]^H\} = \begin{bmatrix} E\{c_1[n]c_1[n]^*\} & E\{c_1[n]c_2[n]^*\} & \cdots & E\{c_1[n]c_L[n]^*\} \\ E\{c_2[n]c_1[n]^*\} & E\{c_2[n]c_2[n]^*\} & \cdots & E\{c_2[n]c_L[n]^*\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{c_L[n]c_1[n]^*\} & E\{c_L[n]c_2[n]^*\} & \cdots & E\{c_L[n]c_L[n]^*\} \end{bmatrix}\quad (3.88)$$

onde o operador hermitiano $\{\cdot\}^H$ representa o conjugado transposto de um vetor ou matriz.

Utilizando (3.84) e (3.85), além de considerar $2\sigma_k^2 = 1$ para qualquer k , tem-se

$$E\{\underline{\mathbf{g}}[n]\underline{\mathbf{g}}[n]^H\} = 2 \begin{bmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_L^2 \end{bmatrix} = \mathbf{I}\quad (3.89)$$

onde \mathbf{I} é a matriz identidade.

De (3.89) e da primeira parte de (3.87), tem-se a matriz de correlação de $\underline{\mathbf{h}}[n]$

$$\Psi_{\mathbf{h}} = E\{\underline{\mathbf{h}}[n]\underline{\mathbf{h}}[n]^H\} = \mathbf{A}E\{\underline{\mathbf{g}}[n]\underline{\mathbf{g}}[n]^H\}\mathbf{A}^H = \mathbf{A}\mathbf{A}^H\quad (3.90)$$

Por outro lado, utilizando a segunda parte de (3.87), verifica-se que $\Psi_{\mathbf{h}}$ é uma matriz hermitiana ($\Psi_{\mathbf{h}}^H = \Psi_{\mathbf{h}}$) com a seguinte forma

$$\Psi_{\mathbf{h}} = E\{\underline{\mathbf{h}}[n]\underline{\mathbf{h}}[n]^H\} = \begin{bmatrix} E\{h_1[n]h_1[n]^*\} & E\{h_1[n]h_2[n]^*\} & \cdots & E\{h_1[n]h_L[n]^*\} \\ E\{h_2[n]h_1[n]^*\} & E\{h_2[n]h_2[n]^*\} & \cdots & E\{h_2[n]h_L[n]^*\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{h_L[n]h_1[n]^*\} & E\{h_L[n]h_2[n]^*\} & \cdots & E\{h_L[n]h_L[n]^*\} \end{bmatrix} \quad (3.91)$$

Por ser hermitiana, $\Psi_{\mathbf{h}}$ possui um conjunto completo de autovetores ortonormais e pode ser diagonalizada por [66]

$$\mathbf{V}^H \Psi_{\mathbf{h}} \mathbf{V} = \mathbf{Z} \quad (3.92)$$

onde \mathbf{V} é uma matriz cujas colunas são formadas pelos autovetores $\{\underline{\mathbf{v}}_1, \underline{\mathbf{v}}_2, \dots, \underline{\mathbf{v}}_L\}$ de $\Psi_{\mathbf{h}}$; \mathbf{Z} uma matriz diagonal formada pelos L respectivos autovalores de $\Psi_{\mathbf{h}}$, ou seja,

$$\mathbf{V} = [\underline{\mathbf{v}}_1 \quad \underline{\mathbf{v}}_2 \quad \cdots \quad \underline{\mathbf{v}}_L] \quad \text{e} \quad \mathbf{Z} = \begin{bmatrix} z_1 & 0 & \cdots & 0 \\ 0 & z_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & z_L \end{bmatrix} \quad (3.93)$$

Como os autovetores de $\Psi_{\mathbf{h}}$ são ortonormais, a matriz \mathbf{V} é unitária, ou seja,

$$\mathbf{V}^H \mathbf{V} = \mathbf{I}. \quad (3.94)$$

Sendo assim, pré e pós multiplicando (3.92) por \mathbf{V} e \mathbf{V}^H , respectivamente, tem-se

$$\Psi_{\mathbf{h}} = \mathbf{V} \mathbf{Z} \mathbf{V}^H, \quad (3.95)$$

que pode ser reescrita por

$$\Psi_{\mathbf{h}} = \mathbf{V} \sqrt{\mathbf{Z}} (\mathbf{V} \sqrt{\mathbf{Z}})^H. \quad (3.96)$$

Finalmente, comparando (3.96) e (3.90), verifica-se que a matriz \mathbf{A} é do tipo

$$\mathbf{A} = \mathbf{V} \sqrt{\mathbf{Z}}. \quad (3.97)$$

A nova matriz \mathbf{C}_T , cujas linhas são compostas pelas componentes multipercurso correlacionadas entre si pode ser encontrada por

$$\mathbf{C}_T = \mathbf{A}\mathbf{C} \quad (3.98)$$

Conclui-se desse desenvolvimento que dada uma matriz de correlação desejada Ψ_h , pode-se obter a matriz \mathbf{C}_T através da transformação (3.98), com a matriz \mathbf{A} sendo dada por (3.97). Por definição, uma matriz de correlação deve ser hermitiana, o que assegura a eficácia do método para qualquer matriz de correlação. Os vetores $\underline{c}_k [n]^T$ que formam as linhas da matriz \mathbf{C} podem ser obtidos de um simulador de canal Rayleigh capaz de gerar L componentes multipercurso não correlacionadas.

3.7 O MODELO COST259

A COST é uma organização intergovernamental europeia para pesquisas técnicas e científicas, fundada em 1971. Desta organização surgiu o simulador computacional de canal de comunicação móvel COST. Sua mais recente versão, o modelo de canal direcional COST259, ou COST259DCM (*directional channel model*), será descrita neste item. Trata-se de um simulador computacional, implementado em MATLAB[®], com as seguintes propriedades [23]

- Reproduz as variações de pequena e larga escala e de perda de percurso;
- Modelo de canal direcional: para uso em antenas adaptativas e diversidade espacial;
- Múltiplos *links* podem ser modelados simultaneamente, com correlações que dependem da separação geográfica entre os móveis.

3.7.1 DESCRIÇÃO DO MODELO

O COST259 gera as componentes multipercurso (MPC) agrupadas em *clusters*. Dá-se o nome de *cluster* ao grupo de componentes multipercurso que percorrem caminhos semelhantes para chegar ao receptor. Para cada móvel simulado o modelo gera no mínimo 1 *cluster*, contendo 40 MPC's.

A Tabela 3.3 ilustra os parâmetros de entrada e saída do modelo.

Tabela 3.3: Parâmetros de entrada e saída do modelo COST259.

Parâmetros de entrada	Parâmetros de saída
<ul style="list-style-type: none"> • vetor posição dos móveis. • frequência da portadora. • tipo de célula. • cenário. • vetor de habilitação. • altura das estações móvel e base. 	<ul style="list-style-type: none"> • potência, atraso, azimute, elevação, atraso de espalhamento, espalhamento de azimute e espalhamento de elevação dos <i>clusters</i>. • amplitude complexa das componentes multipercurso com polarização vertical e horizontal. • atraso absoluto, azimute e elevação das componentes multipercurso. • componentes multipercurso em canal <i>duplex</i>.

Tais parâmetros serão detalhados nos itens que seguem.

3.7.1.1 PARÂMETROS DE ENTRADA

A posição dos móveis deve ser fornecida em coordenadas retangulares através de dois vetores de posições (representando a posição dos móveis nos eixos x e y respectivamente), tendo como referência a posição (0,0) onde está localizada a estação base. O intervalo de tempo assumido entre uma posição do móvel e a posição subsequente é adotado como período de amostragem das componentes multipercurso. Portanto, a velocidade de cada móvel pode ser determinada, a qual não necessariamente precisa ser constante. Mantendo-se o intervalo de amostragem constante e variando-se o tamanho do incremento entre as posições do móvel, tem-se o efeito de uma velocidade variável com o tempo, conforme pode ser verificado na Figura 3.26. A figura ilustra a envoltória de uma componente multipercurso (gerada a partir do COST259) e sua projeção em cada plano do gráfico. Nesse exemplo, na origem dos tempos o móvel tem velocidade igual a 4 km/h e após 0,6 segundo o móvel está a uma velocidade superior a 49 km/h (aceleração constante e igual a 21 m/s²). Observa-se que a taxa de ocorrência de nulos aumenta com o tempo, mas os nulos ainda ocorrem aproximadamente a cada $\frac{1}{2}$ comprimento de onda λ . Tem-se nesse caso uma frequência Doppler máxima que varia com o tempo.

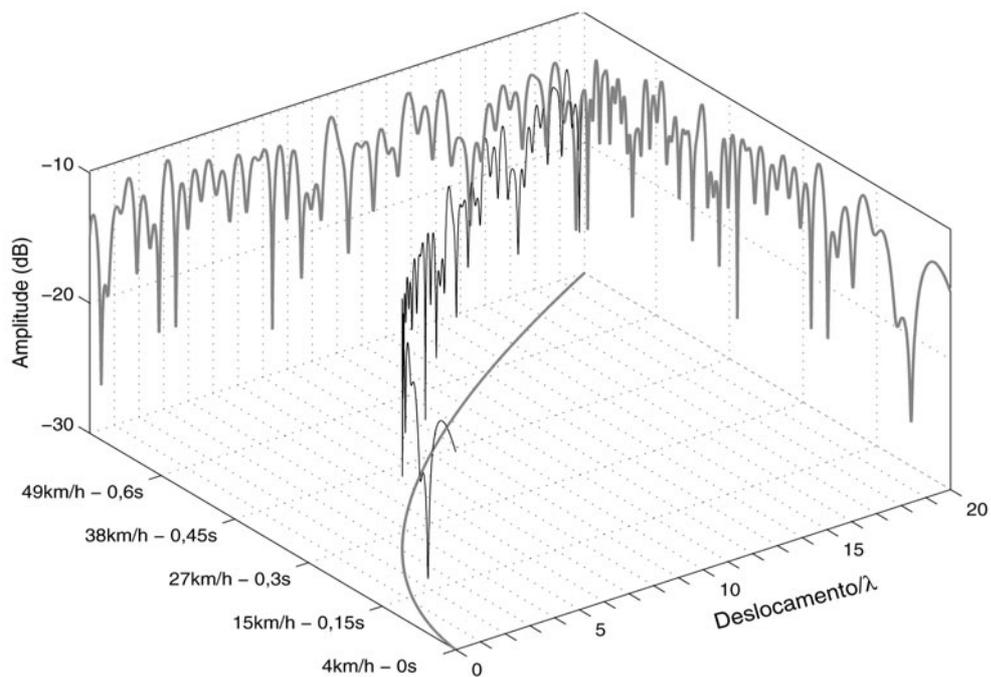


Figura 3.26: Envoltória de uma componente multipercurso gerada com velocidade do móvel variante no tempo.

O simulador gera em cada chamada internamente uma célula com características próprias, como espalhadores, linha de visada, sombreamento, etc. Virtualmente, para cada posição (x,y) da célula, o modelo tem definido o respectivo coeficiente de canal. Desta forma, existe correlação entre os coeficientes de canal de móveis que estão próximos, chegando à igualdade de resposta caso estejam na mesma posição. Quando os parâmetros de saída são devolvidos, as informações sobre a célula são descartadas, para que em novas chamadas com posições iguais às anteriores, o modelo gere coeficientes diferentes (pois uma nova célula será criada com outras características) [67].

Quanto à frequência da portadora o modelo foi testado e validado na faixa de 1 a 2 GHz, mas pode ser utilizado na faixa de 450 MHz a 5 GHz [67]. Quanto ao ambiente de propagação, a célula foi dividida em 3 tipos, cada qual com seus cenários específicos (as palavras entre ‘ ’ indicam o nome do parâmetro de entrada no simulador) :

a) ‘macro’ : Macro célula (estação base acima do nível dos prédios);

Cenários possíveis:

- ‘*TU*’ : típico urbano;
- ‘*BU*’ : urbano denso (*Bad Urban*);
- ‘*HT*’ : terreno montanhoso;
- ‘*RA*’ : área rural.

b) ‘*micro*’: Microcélula (estação base abaixo do nível dos prédios);

Cenários possíveis:

- ‘*SC*’ : estradas em cânion;
- ‘*OP*’ : ambientes abertos;
- ‘*SN*’ : estradas em cânion, sem linha de visada;
- ‘*SX*’ : cruzamentos de ruas.

c) ‘*pico*’ : Picocélula (estação base em ambiente interno).

Cenários possíveis:

- ‘*TC*’ : corredores;
- ‘*FA*’ : fábricas;
- ‘*OR*’ : escritórios;
- ‘*OL*’ : saguão, ambiente interno aberto.

Os tipos de célula *b* e *c* não serão comentados neste trabalho.

O vetor de habilitação torna possível escolher dentre os vários parâmetros de simulação que o modelo dispõe, somente os de interesse. Trata-se de um vetor linha com 16 posições, onde cada posição corresponde a um determinado parâmetro. Os valores ‘1’ ou ‘0’ devem ser atribuídos à posição do vetor referente ao parâmetro que se deseja habilitar ou desabilitar, respectivamente. Segue uma lista dos parâmetros de habilitação (na ordem em que aparecem no vetor de habilitação) com o nome (em inglês) e o significado de cada parâmetro no estado habilitado:

- *Spatial*: introduz o ângulo de azimute nos percursos;

- **Wideband**: introduz o atraso no tempo nos percursos;
- **Elevation**: introduz o ângulo de elevação nos percursos;
- **Polarization**: introduz a polarização nos percursos. Se igual '0' devolve somente a polarização vertical;
- **PolarizationVar**: introduz variações de larga escala na polarização dos percursos;
- **ClusterBirthDeath**: introduz variações de larga escala no número de clusters dos percursos;
- **PathLoss**: introduz a perda de percurso na potência média da resposta impulsiva (IR) do canal;
- **ShadowFading**: introduz os efeitos de sombreamento na IR do canal;
- **LargeScaleVar**: introduz variações de larga escala no sombreamento, espalhamento de atraso e espalhamento de azimute;
- **FastFading**: introduz os efeitos de desvanecimento rápido na IR do canal;
- **ClusterPositionVar**: os clusters dos percursos se agrupam em atraso, azimute e elevação de acordo com o movimento do móvel;
- **LOSBirthDeath**: introduz mudanças dinâmicas na ocorrência de linha de visada;
- **MPCPositionVar**: não implementado;
- **RiceVar**: introduz variações de larga escala nas estatísticas de desvanecimento rápido;
- **Duplex**: gera a IR para os canais direto e reverso;
- **Indoor**: móveis em ambiente interno.

3.7.1.2 PARÂMETROS DE SAÍDA

Os parâmetros de saída estão listados abaixo, na ordem em que aparecem no modelo.

- Potência média de clusters;
- Atraso do primeiro percurso em um cluster;

- Ângulo médio de azimute dos clusters;
- Ângulo médio de elevação dos clusters;
- Espalhamento de atraso dos clusters;
- Espalhamento de azimute dos clusters;
- Espalhamento de elevação dos clusters;
- Amplitudes complexas da componente de polarização vertical dos percursos;
- Amplitudes complexas da componente de polarização horizontal dos percursos;
- Atraso absoluto dos percursos;
- Ângulo de azimute dos percursos referente ao eixo x;
- Ângulo de elevação dos percursos referente ao plano xy;
- Amplitudes complexas da componente verticalmente polarizada do percurso no canal duplex;
- Amplitudes complexas da componente horizontalmente polarizada do percurso no canal duplex.

3.7.2 SOBRE A GERAÇÃO DE CLUSTERS

O modelo gera pelo menos um cluster em cada chamada, o qual ocorre devido ao espalhamento local (vizinhança) do móvel. Clusters adicionais podem ocorrer devido ao espalhamento em construções distantes, montanhas etc. Cada *cluster* é composto por 40 MPC's (quantidade fixa e inerente ao modelo). O número de *clusters* gerado em cada simulação é uma variável aleatória com distribuição de Poisson, cujo valor médio depende do cenário escolhido. Para o cenário 'BU', por exemplo, é típica a ocorrência de mais de dois *clusters*, ou seja, mais de 80 componentes multipercurso.

Se o parâmetro *ClusterBirthDeath* (vetor de habilitação) estiver habilitado, haverá uma variação dinâmica no número de clusters adicionais. O surgimento ou desaparecimento de um cluster adicional será função da posição do móvel. Quando o simulador gera uma célula, são criadas as chamadas "áreas de visibilidade", que são áreas circulares com raio definido de acordo com o cenário em questão. Um cluster é

ativado quando o móvel entra em uma área de visibilidade e desativado quando o móvel sai da mesma. A Figura 3.27 ilustra tal situação. O raio da área de visibilidade assume os valores 100 m, 100 m, 300 m e 300 m para os cenários 'TU', 'BU', 'RA' e 'HT', respectivamente [23],[67].

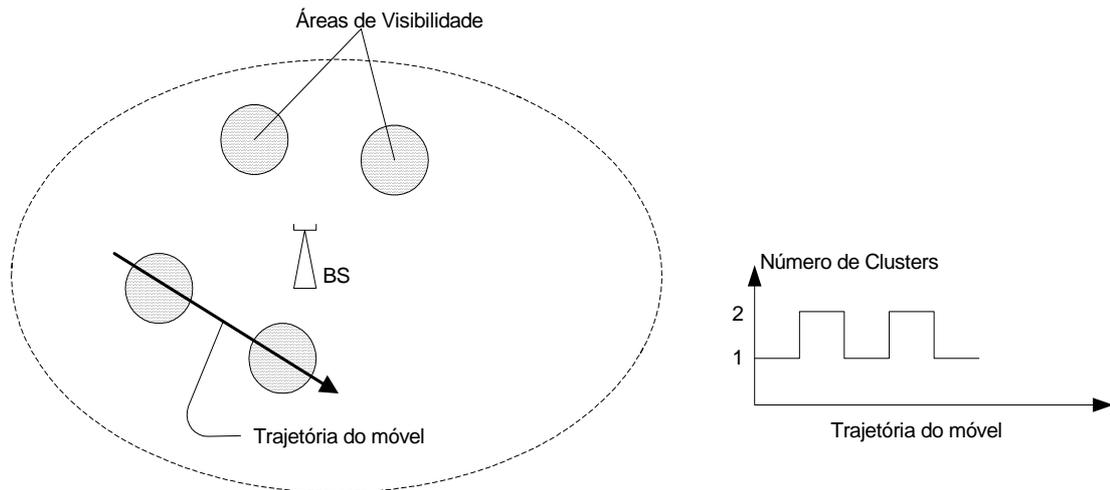


Figura 3.27: Número de clusters como função da posição do móvel.

FONTE: ERICSSON INTERNAL REPORT [23], 2001.

No caso estático (*ClusterBirthDeath* desabilitado), o número de clusters é fixo do início ao fim da simulação e dado por [13]:

$$N_{cluster} = 1 + x_p \quad (3.99)$$

onde x_p é um processo aleatório de Poisson com valor médio igual a N_0 e função massa de probabilidade dada por

$$P\{x_p = k \text{ clusters}\} = (N_0)^k \frac{e^{-N_0}}{k!}, \quad k \geq 0 \quad (3.100)$$

Substituindo (3.99) em (3.100) tem-se a probabilidade de ocorrência de um determinado número de cluster:

$$P\{N_{cluster} = 1 + k \text{ clusters}\} = (N_0)^k \frac{e^{-N_0}}{k!}, \quad k \geq 0 \quad (3.101)$$

O valor de N_0 é definido de acordo com o cenário em questão e provém de medidas de perfil atraso-potência [23]:

- ‘TU’: $N_0 = 0,17$;
- ‘BU’: $N_0 = 1,18$;
- ‘RA’: $N_0 = 0,06$;
- ‘HT’: $N_0 = 1,18$.

Em ambientes densamente urbanizados e terrenos montanhosos (por razões do elevado número de obstáculos presentes) teoricamente há um número maior de caminhos que o sinal pode percorrer até chegar ao receptor, resultando em um maior número de *clusters*. O contrário vale para ambientes rurais (não montanhosos). Isto justifica os valores de N_0 encontrados em cada cenário, uma vez que o mesmo é diretamente proporcional à probabilidade de ocorrência de *cluster*.

A Tabela 3.4 ilustra a probabilidade de ocorrer exatamente $N_{cluster}$ em uma simulação estática, de acordo com o cenário. Observa-se que nos ambientes ‘TU’ e ‘RA’ ocorrerá somente um cluster em 84% e 94% das simulações, respectivamente. Já nos ambientes ‘BU’ e ‘HT’ as chances de ocorrerem 1, 2 ou 3 clusters estão próximas e são 31% 36% e 21%, respectivamente. A Tabela 3.5 ilustra a probabilidade de ocorrência de clusters adicionais.

3.7.3 SOBRE A OCORRÊNCIA DE LINHA DE VISADA

A ocorrência de linha de visada no COST259 tem função massa de probabilidade dada por [23]:

$$P_{LoS}(d, h_{rf}) = \begin{cases} \frac{d_{co} - d}{d_{co}} \cdot \frac{h_{bs} - h_{rf}}{h_{bs}} & , \quad d < d_{co}, \quad h_{rf} < h_{bs} \\ 0 & , \quad \text{caso contrário} \end{cases} \quad (3.102)$$

onde d é a distância entre o móvel e a BS, h_{bs} é a altura da estação base, h_{rf} é a

altura média dos edifícios e d_{co} é a máxima distância que o móvel deve estar para que haja probabilidade de ocorrência de linha de visada, chamada de distância de corte. A Figura 3.28 ilustra um gráfico, com curvas de nível, da probabilidade de ocorrência de LoS dada por , em escala normalizada.

Tabela 3.4: Probabilidade de ocorrência de um determinado número de cluster.

$N_{cluster}$	Probabilidade de ocorrer exatamente $N_{cluster}$		
	‘TU’	‘BU’ e ‘HT’	‘RA’
1	$8,4366 \times 10^{-1}$	$3,0728 \times 10^{-1}$	$9,4176 \times 10^{-1}$
2	$1,4342 \times 10^{-1}$	$3,6259 \times 10^{-1}$	$5,6506 \times 10^{-1}$
3	$1,2191 \times 10^{-2}$	$2,1393 \times 10^{-1}$	$1,6952 \times 10^{-3}$
4	$6,9082 \times 10^{-4}$	$8,4145 \times 10^{-2}$	$3,3904 \times 10^{-5}$
5	$2,9360 \times 10^{-5}$	$2,4823 \times 10^{-2}$	$5,0855 \times 10^{-7}$
6	$9,9824 \times 10^{-7}$	$5,8582 \times 10^{-3}$	$6,1026 \times 10^{-9}$
7	$2,8283 \times 10^{-8}$	$1,1521 \times 10^{-3}$	$6,1026 \times 10^{-11}$
8	$6,8688 \times 10^{-10}$	$1,9421 \times 10^{-4}$	$5,2308 \times 10^{-13}$
9	$1,4596 \times 10^{-11}$	$2,8646 \times 10^{-5}$	$3,9231 \times 10^{-15}$
10	$2,7571 \times 10^{-13}$	$3,7558 \times 10^{-6}$	$2,6154 \times 10^{-17}$

Tabela 3.5: Probabilidade de ocorrer clusters adicionais.

Cenário	$P\{N_{cluster} > 1\}$
‘TU’	0,15634
‘BU’ e ‘HT’	0,69272
‘RA’	0,05823

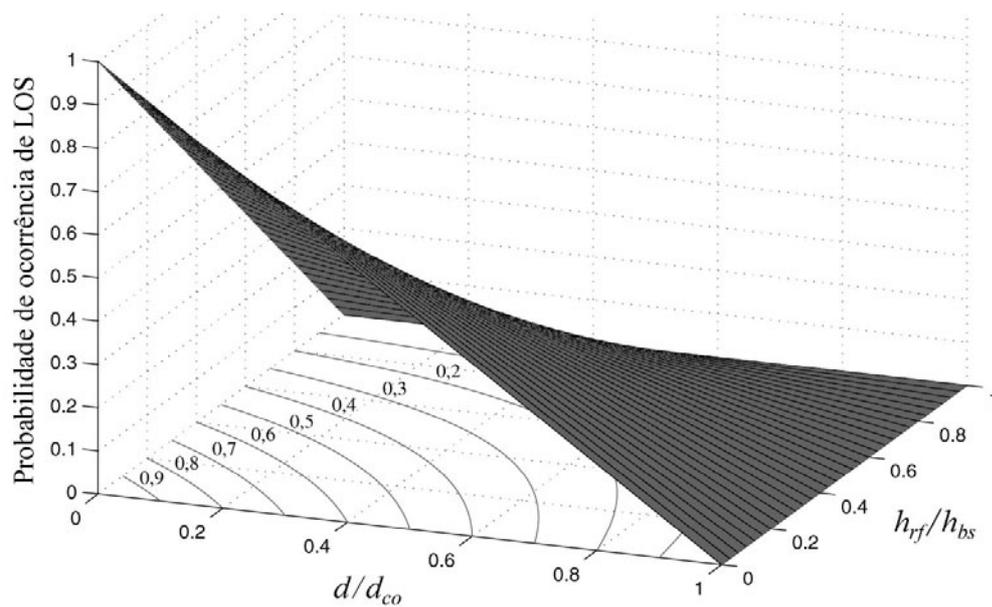


Figura 3.28: Probabilidade de ocorrência de linha de visada no modelo COST259.

Os valores atribuídos a h_{bs} , h_{rf} e d_{co} encontram-se na Tabela 3.6.

Tabela 3.6: Valores de alguns parâmetros de cenário no modelo COST259.

Parâmetro	Cenário			
	'TU'	'BU'	'RA'	'HT'
h_{BS} (m)	30	50	50	50
h_B (m)	15	30	5	5
d_{co} (km)	0,5	0,5	5	5
R_{LD} (m)	30	30	100	100

FONTE: ERICSSON INTERNAL REPORT [23],[22], 2001.

Para variações dinâmicas na ocorrência de LoS (surgimento/desaparecimento) um modelo similar àquele apresentado na Figura 3.27 é adotado, onde um número de áreas circulares com raio R_{LD} é utilizado. A Tabela 3.6 ilustra os valores de R_{LD} para cada cenário.

3.7.4 SOBRE A PERDA DE PERCURSO

Considerando a frequência de propagação de 2 GHz, foi escolhido para modelar a perda de percurso o modelo COST231–Hata (para os ambientes: área rural e terreno montanhoso) e o modelo COST231–WI (para os ambientes urbano típico e urbano denso). Ambos estão descritos no Capítulo 2.

3.7.5 SOBRE A CORRELAÇÃO TEMPORAL DAS COMPONENTES MULTIPERCURSO

MULTIPERCURSO

Visando verificar o grau de correlação temporal entre as componentes multipercurso de um único móvel, foi realizada uma simulação com retorno de dois clusters, seguida do cálculo da covariância temporal normalizada (veja (A.19)) entre todas as MPC's geradas. Foram geradas 80 MPCs distribuídas em 2 *clusters*. O número de amostras utilizadas foi 20.000, com período de amostragem $T_s = 245 \mu\text{s}$. O vetor de habilitação foi configurado para simulação apenas do desvanecimento rápido e sem linha de visada. Optou-se por simular o ambiente típico urbano. A largura de banda BW utilizada, foi de 3,84 MHz. A Figura 3.29 ilustra o perfil atraso-potência das 80 componentes multipercurso geradas, onde os atrasos estão normalizados em $T_c = 1/BW$. Nota-se um perfil exponencial de potência para os dois *clusters* e um intervalo de mais de $15 T_c$ ($3,9 \mu\text{s}$) entre um *cluster* e outro.

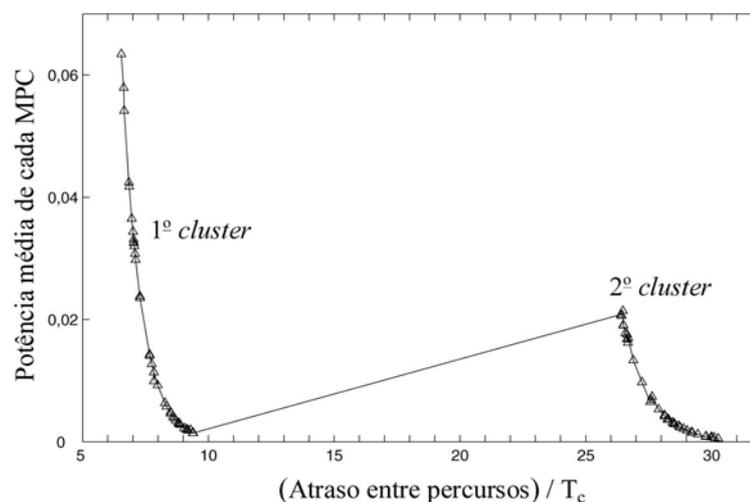


Figura 3.29: Perfil atraso-potência das componentes multipercurso.

Foi considerado um deslocamento de 0 a 40 amostras, ou seja, τ variando de 0 a $40 T_s$ (9,8 ms). Para esses valores de parâmetros de simulação a covariância temporal normalizada $\overline{C_{ij}^n}(\tau)$ será uma matriz quadrada de dimensão 80 (simétrica e sem a diagonal principal) para cada valor de τ , totalizando 3.160 valores de coeficientes de correlação para cada deslocamento. Visando simplificar a análise, foi definida uma matriz complexa que contém os valores máximos de correlação entre as componentes multipercurso i e j :

$$CC_{ij}^{\max} = \max_{\tau} \left[\overline{C_{ij}^n}(\tau) \right], \quad i \neq j \quad (3.103)$$

A matriz CC_{ij}^{\max} é simétrica e divide-se em três partes: correlações entre MPC's do primeiro cluster, do segundo cluster e entre MPC's de clusters diferentes, conforme ilustra Figura 3.30.

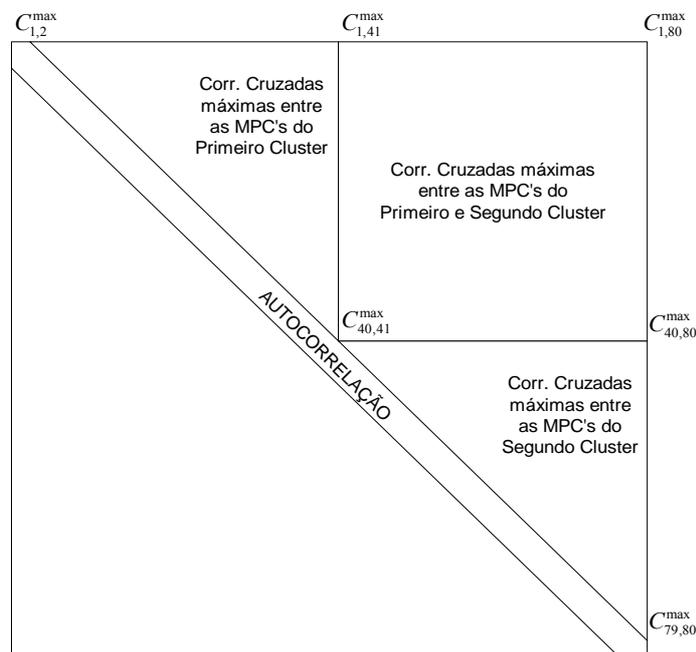


Figura 3.30: Matriz de valores máximos de correlação entre as componentes multipercurso.

Utilizando os dados obtidos por simulação foi calculada a matriz complexa CC_{ij}^{\max} , a qual está ilustrada na Figura 3.31, através do módulo de suas partes real e imaginária.

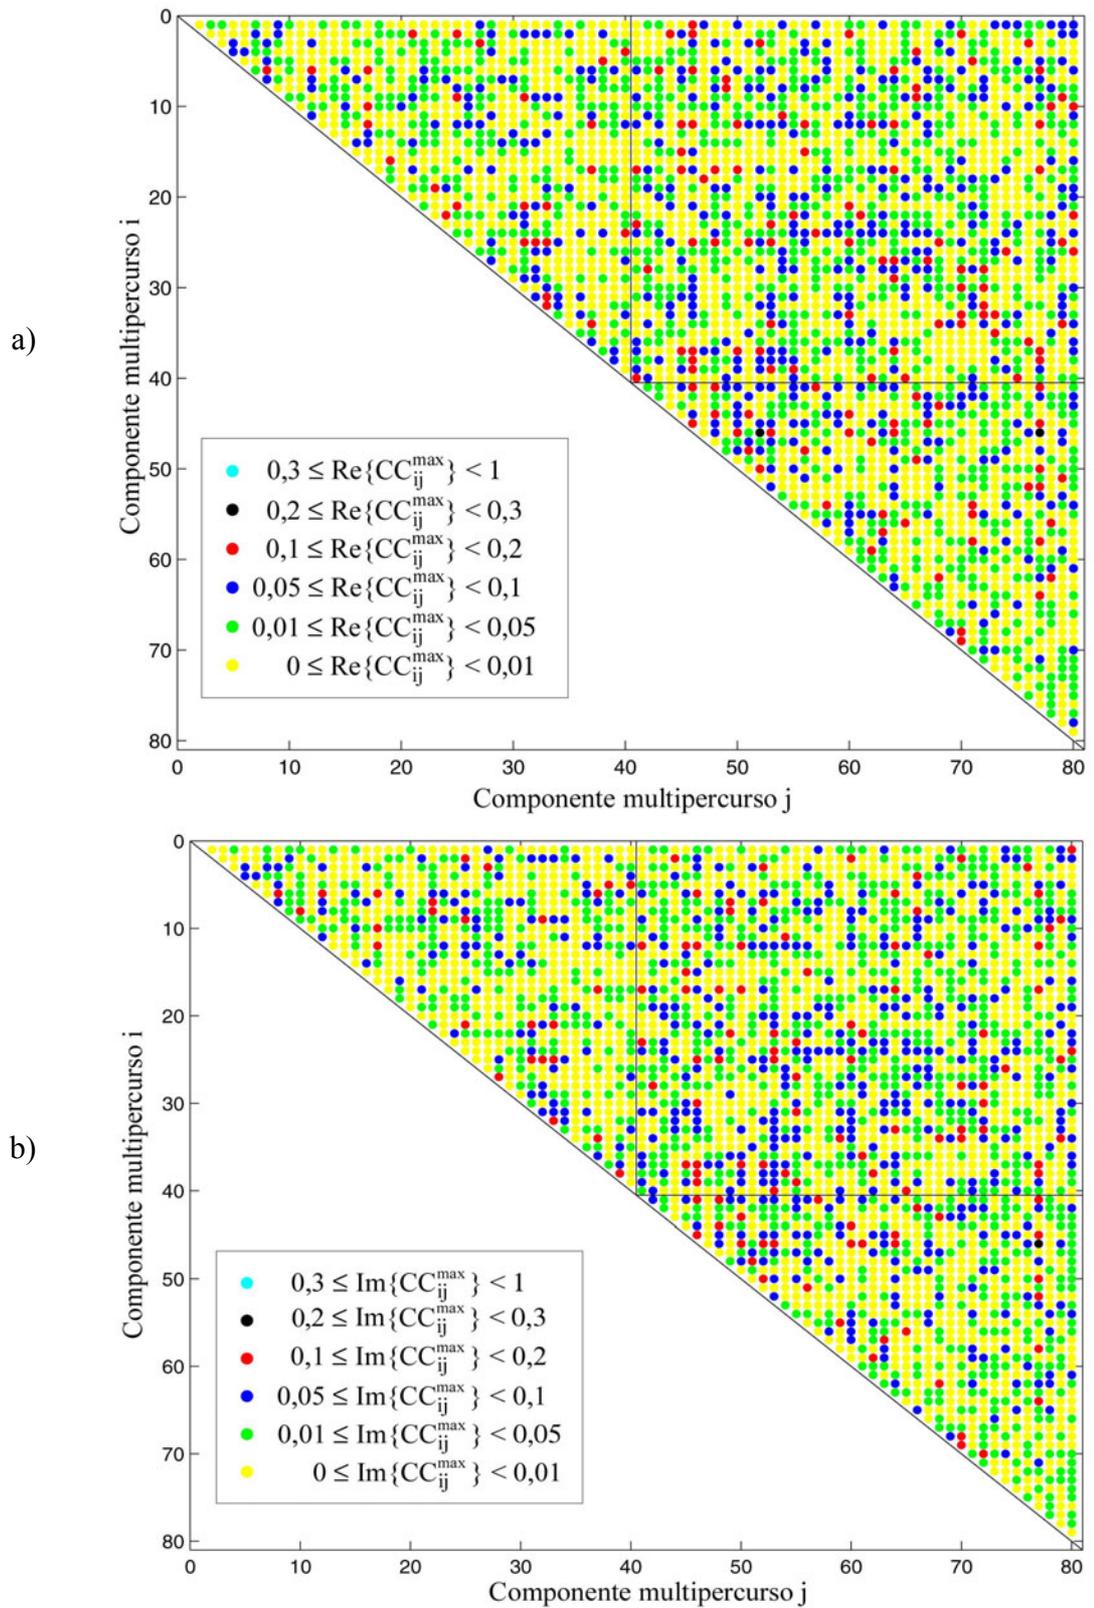


Figura 3.31: Matriz de correlação cruzada máxima. a) parte real e b) parte imaginária.

Teoricamente, duas componentes multipercurso pertencentes a *clusters* diferentes deveriam ser não correlacionadas, pois percorrem caminhos diferentes, sofrendo diferentes reflexões, refrações, difrações e atrasos. Conseqüentemente, o quadrante superior direito da matriz de correlação deveria ter uma ocorrência maior de regiões amarelas e verdes (por exemplo) que nos demais. Nota-se porém (por inspeção), que os valores de coeficientes de correlação estão igualmente distribuídos em cada quadrante da matriz. Além disso, a ocorrência de várias regiões vermelhas no quadrante superior direito indica um grau de correlação, para componentes pertencentes a *clusters* diferentes, entre 10% e 20% do valor máximo.

Os valores de correlação encontrados são relativamente elevados e são contrários às recentes publicações [7],[11],[16] onde há um esforço para que múltiplas formas de ondas não correlacionadas sejam obtidas. Porém, esses valores diminuirão com um aumento no número de amostras.

3.7.6 SOBRE A CORRELAÇÃO ESPACIAL ENTRE MÓVEIS DIFERENTES

No item 3.3.1.1 foi mencionado que existe correlação entre as componentes multipercurso de móveis que estão próximos um do outro. Para verificar esse grau de correlação espacial entre as componentes multipercurso de dois móveis, foi realizada uma simulação com o modelo. Para tal, foram consideradas três situações de movimento retilíneo uniforme: móveis na mesma direção e sentido, móveis na mesma direção e sentidos opostos e móveis com direção perpendicular. A Figura 3.32 ilustra estas três situações. O movimento dos móveis se dá no primeiro quadrante de uma célula onde a unidade base se encontra nas coordenadas retangulares (0,0).

Para cada situação variou-se a distância d inicial entre os dois móveis e calculou-se o coeficiente de correlação, sendo tomado apenas o seu valor máximo no intervalo considerado. Para o cálculo do coeficiente de correlação tomou-se apenas a componente multipercurso de menor atraso (teoricamente a de maior potência) de cada móvel.

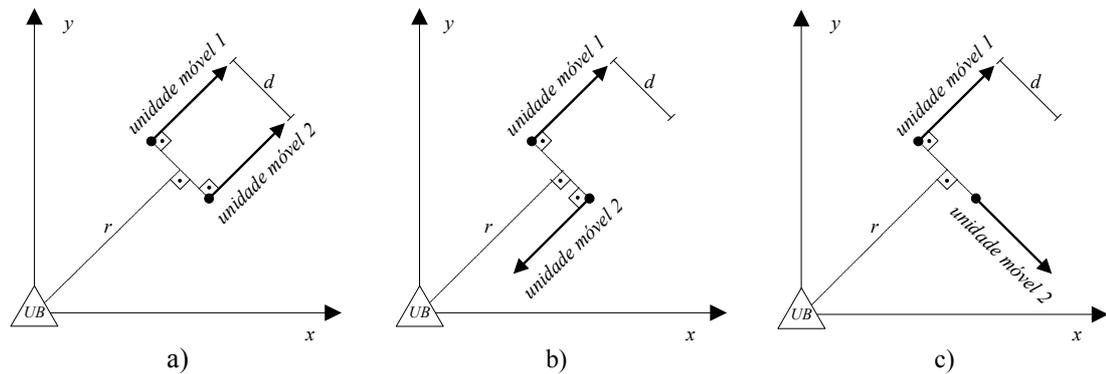


Figura 3.32: Trajetória tomada pelas unidades móveis na simulação. a) paralelo; b) paralelo sentido oposto e c) perpendicular.

Parâmetros de simulação:

- vetor de habilitação: somente desvanecimento rápido e sem linha de visada;
- ambiente: macrocélula, urbano típico com $f_m = 100$ Hz;
- $T_s = 245$ μ s, r fixo e igual a 2 km e d variável de 0 a 1 km;
- deslocamento (cálculo da correlação) de 0 a 80 amostras, τ variando de 0 a $80T_s$ (19,6ms);
- total de amostras = 5.000.

O resultado da simulação está ilustrado na Figura 3.33. Cada coluna de dois gráficos representa uma situação de simulação (descrita na própria figura). Os três gráficos superiores e inferiores representam respectivamente as partes real e imaginária (em módulo) da covariância temporal normalizada (valor máximo) para cada situação. Observa-se que a correlação no movimento paralelo varia no intervalo que vai de 0 à 0,7. Já para o deslocamento paralelo com sentido oposto, a correlação está na faixa de 0 a 0,35 e para o deslocamento perpendicular a faixa é de 0 a 0,3. Observa-se nos três casos que os valores de correlação variam independentemente da distância d . Por outro lado fica claro que a correlação está relacionada com a direção e sentido tomados pelos móveis. Observa-se, por exemplo, no deslocamento paralelo que mesmo para distâncias superiores a 200 m há valores de correlação superiores a 0,5, enquanto nos outros casos os valores não passam de 0,35.

Os gráficos (escala logarítmica) não ilustram coeficiente de correlação para $d = 0$. São eles:

- Deslocamento paralelo: $\max_{\tau} [\overline{C_{ij}^n}(\tau)](d = 0) = 1$;
- Deslocamento paralelo sentido contrário: $\max_{\tau} [\overline{C_{ij}^n}(\tau)](d = 0) = 0,0126 + j 0,0342$;
- Deslocamento perpendicular: $\max_{\tau} [\overline{C_{ij}^n}(\tau)](d = 0) = 0,0162 + j 0,0888$.

No deslocamento paralelo, quando $d = 0$, os dois móveis estão exatamente na mesma posição. Nesse caso, o modelo devolve a mesma resposta (mesma forma de onda) para ambos e a correlação é igual a 1 (autocorrelação em fase).

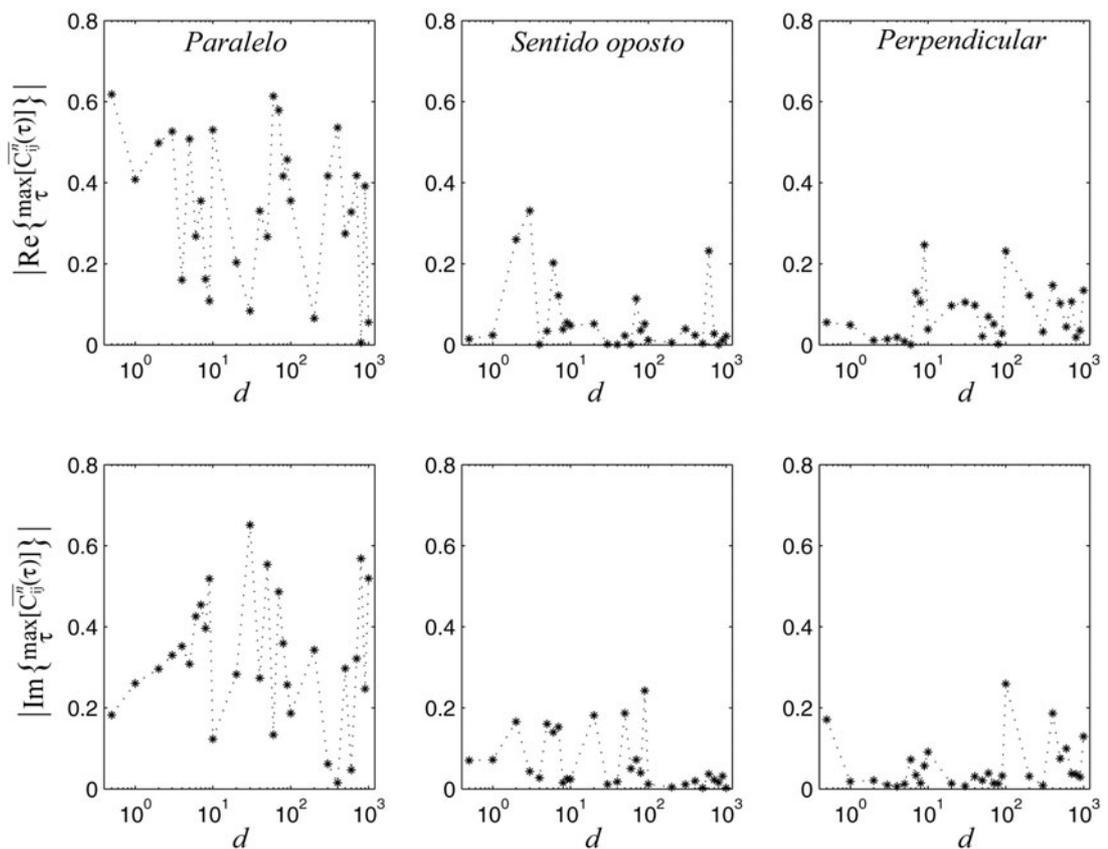


Figura 3.33: Correlação espacial entre as MPC com menor atraso de cada móvel.

CAPÍTULO 4

MODELO PROPOSTO

Descreve-se nesta seção um novo simulador de canal com desvanecimento multipercurso, cujos coeficientes de transmissão formam um processo aleatório complexo Gaussiano passa-baixas, com largura de banda f_m , que apresenta todas as propriedades estatísticas em (3.14).

4.1 APRESENTAÇÃO DO MODELO PROPOSTO

Sob a hipótese dos coeficientes de transmissão $c(t)$ formarem um processo aleatório ergódico em função de autocorrelação, como no modelo de Clarke, sua densidade espectral de potência pode ser escrita por [68]

$$\lim_{T \rightarrow \infty} \left(\frac{|S_T(f)|^2}{T} \right) \quad (4.1)$$

onde $S_T(f) = F\{c(t)\}$ é a transformada de Fourier de $c(t)$ num intervalo de tempo T segundos. Por outro lado, adotando o modelo de propagação de Clarke, sem linha de visada e considerando uma antena omnidirecional, o espectro de potência de $c(t)$ é bem conhecido e dado por (3.13), que em banda base resulta em

$$S_n(f) = \frac{1}{\pi f_m \sqrt{1 - \left(\frac{f}{f_m}\right)^2}}, \quad |f| \leq f_m \quad (4.2)$$

onde a potência total em $S_n(f)$ está normalizada, ou seja,

$$\int_{-f_m}^{+f_m} S_n(f) df = 1 \quad (4.3)$$

Desta forma, em um processo aleatório com valor médio quadrático $2\sigma^2$ a densidade espectral de potência será

$$S_s(f) = 2\sigma^2 S_n(f)$$

Agora, igualando esse resultado com (4.1) e assumindo um intervalo de tempo T suficientemente grande, pode-se escrever

$$|S_T(f)| = \sqrt{TS_s(f)} \quad \Rightarrow \quad S_T(f) = |S_T(f)| e^{j\varphi(f)} = \sqrt{2\sigma^2 TS_n(f)} e^{j\varphi(f)} \quad (4.4)$$

Finalmente, aplicando a transformada de Fourier inversa em (4.4), os coeficientes de transmissão podem ser obtidos

$$\tilde{c}(t) = F^{-1}\{S_T(f)\} = F^{-1}\left\{\sqrt{2\sigma^2 TS_n(f)} e^{j\varphi(f)}\right\} \quad (4.5)$$

Esta relação mostra que é possível obter $c(t)$ a partir de seu espectro de potência caso a fase $\varphi(f)$ seja conhecida. Para assegurar que as propriedades estatísticas apresentadas pelo modelo casem perfeitamente com as propriedades em (3.14), a fase $\varphi(f)$ é assumida ser uniformemente distribuída no intervalo $[0, 2\pi)$.

Para possibilitar a implementação do modelo é necessário transformar (4.5) em uma equação equivalente para valores discretos. Considere uma seqüência complexa $c[n]$ com comprimento N , representando $c(t)$ em tempo discreto e com período de amostragem $T_s = 1/f_s$. A relação entre $|S_T(f)| = F\{c(t)\}$ e seu equivalente amostrado no tempo e frequência $|S_T[k]| = |\text{DFT}\{c[n]\}|$ (onde DFT é a transformada discreta de Fourier) é dada por (veja APÊNDICE C)

$$|S_T[k]| = \frac{1}{T_s} |S_T(kT_f)| = \frac{1}{T_s} \sqrt{2\sigma^2 TS_n(kT_f)} \quad (4.6.a)$$

$$= \sqrt{2\sigma^2 \frac{N}{T_s} S_n(kT_f)} \quad (4.6.b)$$

$$= \sqrt{2\sigma^2 N S_n[k]} \quad (4.6.c)$$

onde $T_f = 1/T$ Hz é o intervalo entre duas componentes de frequência de $|S_T[k]|$ e

$T = NT_s$ é o intervalo de tempo em (4.1). Substituindo (4.2) em (4.6.b) $|S_T[k]|$ vem a ser

$$|S_T[k]| = \begin{cases} 0, & k = 0 \\ \sqrt{\left(\frac{2\sigma^2 N}{T_s}\right) \frac{1}{\pi f_m \sqrt{1 - \left(\frac{kT_f}{f_m}\right)^2}}}, & 1 \leq k \leq K_m - 1 \\ \sqrt{\left(\frac{2\sigma^2 N}{T_f T_s}\right) \left(\frac{1}{2} - \frac{1}{\pi} \arcsin\left(\frac{(K_m - 1)T_f}{f_m}\right)\right)}, & k = K_m \\ 0, & K_m + 1 \leq k \leq N - 1 - K_m \\ |S_T[N - k]|, & N - K_m \leq k \leq N - 1 \end{cases} \quad (4.7)$$

onde K_m foi definido em (3.75). Foi escolhido $|S_T[0]| = 0$ para garantir ergodicidade em média (veja equações (4.21) e (4.22)). Já a expressão que define $|S_T[k = K_m]|$ foi encontrada através de um processo de interpolação descrito a seguir. Ambos os procedimentos também foram adotados em [6] e [15].

Seja A_m a área sob a curva $S_n(f)$ de $(K_m - 1)T_f$ a $K_m T_f$, conforme ilustra a Figura 4.1.

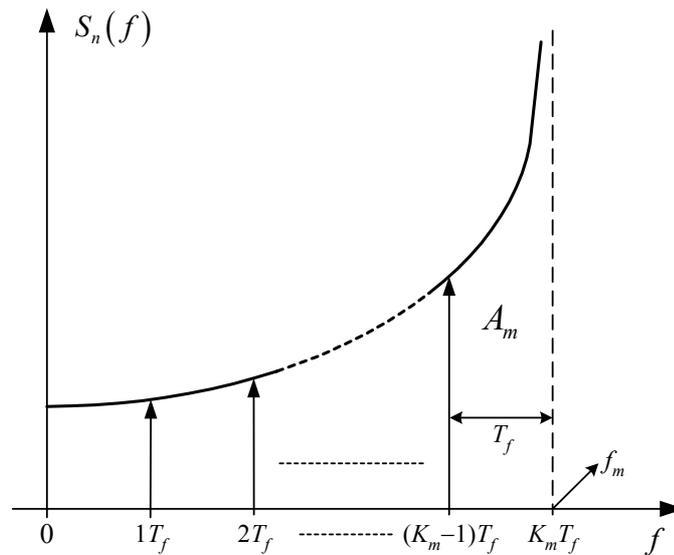


Figura 4.1: Figura utilizada para ilustrar o procedimento de interpolação.

Aproximando A_m por um retângulo de altura $S_n(K_m T_f)$ e base T_f e utilizando (4.3), tem-se

$$\frac{1}{2} \int_0^{(K_m-1)T_f} S_n(f) df = S_n(K_m T_f) T_f$$

Resolvendo para $S_n(K_m T_f)$

$$S_n(K_m T_f) = \frac{1}{T_f} \left(\frac{1}{2} - \frac{1}{\pi} \arcsin \left(\frac{(K_m-1)T_f}{f_m} \right) \right)$$

e substituindo o resultado em (4.6.b), tem-se

$$|S_T[k = K_m]| = \sqrt{2\sigma^2 \frac{N}{T_s T_f} \left(\frac{1}{2} - \frac{1}{\pi} \arcsin \left(\frac{(K_m-1)T_f}{f_m} \right) \right)} \quad (4.8)$$

que é a expressão utilizada em (4.7).

Finalmente, os coeficientes de transmissão discretos podem então ser obtidos por

$$\begin{aligned} \tilde{c}[n] &= \text{IDFT} \left\{ |S_T[k]| e^{j\varphi_k} \right\} \\ &= \frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| e^{j(\varphi_k + 2\pi kn/N)}, \quad n = 0, 1, \dots, N-1 \end{aligned} \quad (4.9)$$

onde agora $\varphi[k] = \{\varphi_0, \varphi_1, \dots, \varphi_k, \dots, \varphi_{N-1}\}$ é uma seqüência de variáveis aleatórias independentes e uniformemente distribuídas no intervalo $[0, 2\pi)$.

Para obter uma função amostra discreta $\tilde{c}[n]$ do processo, escolhe-se os valores desejados para $2\sigma^2$, f_m , T_s , N e calcula-se (4.7), multiplicando cada amostra da seqüência $|S_T[k]|$ pelos respectivos ângulos de fase em $\varphi[k]$. Por último, calcula-se a IDFT da seqüência resultante como em (4.9). A Figura 4.2 ilustra um diagrama de blocos do modelo proposto.

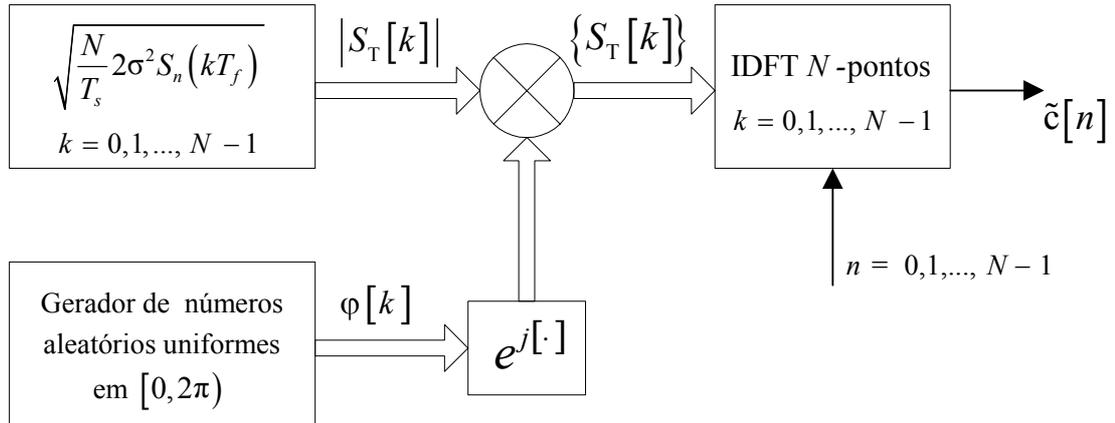


Figura 4.2: Diagrama de blocos do modelo proposto.

Observe que reescrevendo (3.73) (modelo de Young) em sistema de coordenadas polares, tem-se

$$y[n] = \frac{1}{N} \sum_{k=0}^{N-1} F_M[k] (D[k] e^{j\varphi_k}) e^{j2\pi kn/N}, \quad n = 0, 1, \dots, N-1 \quad (4.10)$$

onde $D[k] = \sqrt{A[k]^2 + B[k]^2}$ é uma variável aleatória Rayleigh e $\varphi_k = \arctan(B[k]/A[k])$ é uma variável aleatória uniforme no intervalo $[0, 2\pi)$ [43]. Comparando (4.10) e (4.9) verifica-se claramente que a principal diferença entre os dois modelos é a variável aleatória Rayleigh $D[k]$ presente no modelo de Young e ausente no modelo proposto. Além disso, eles diferem em algumas constantes de filtro (compare (3.74) e (4.7)). O número de operações IDFT será o mesmo para ambos, mas, enquanto o modelo de Young requer dois geradores de números aleatórios, o modelo proposto requer apenas um.

Observe ainda que apesar de ter sido desenvolvido de maneira independente do modelo de Smith, o modelo proposto também pode ser considerado uma versão modificada desse modelo. Nesse caso, a quantidade de geradores de números aleatórios diminui de 4 para somente 1, enquanto suas propriedades estatísticas foram mantidas corretas, conforme será verificado a seguir.

4.2 PROPRIEDADES ESTATÍSTICAS DO MODELO PROPOSTO

Dado que o objetivo do simulador é modelar estatisticamente um canal com desvanecimento, é conveniente que o processo aleatório resultante apresente as mesmas propriedades estatísticas do processo aleatório que caracteriza fisicamente um canal com desvanecimento. Nesta seção, as propriedades estatísticas do modelo são apresentadas de forma analítica.

Separando (4.9) em partes real $\tilde{c}_R[n]$ e imaginária $\tilde{c}_I[n]$, tem-se

$$\tilde{c}_R[n] = \frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| \cos(\varphi_k + 2\pi kn/N) \quad (4.11)$$

$$\tilde{c}_I[n] = \frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| \sin(\varphi_k + 2\pi kn/N) \quad (4.12)$$

As equações (4.11) e (4.12) apresentam um somatório de variáveis aleatórias independentes. Isto torna possível, considerando N grande o suficiente para tal (valores práticos de N estão acima de 500), a aplicação do TLC, caracterizando $\tilde{c}_R[n]$ e $\tilde{c}_I[n]$ como processos aleatórios Gaussianos e $\tilde{c}[n]$ como um processo aleatório complexo Gaussiano. Conseqüentemente, esse processo é completamente definido por sua função de autocorrelação e valor médio.

4.2.1 MÉDIAS ESTATÍSTICAS

Da definição de $\varphi[k]$, pode-se concluir que

$$E\{\cos \varphi_k\} = 0 = E\{\sin \varphi_k\} \quad (4.13)$$

Conseqüentemente,

$$E\{e^{j\varphi_k}\} = E\{\cos \varphi_k\} + jE\{\sin \varphi_k\} = 0 \quad (4.14)$$

Segue desse desenvolvimento os valores esperados de $\tilde{c}[n]$, $\tilde{c}_R[n]$ e $\tilde{c}_I[n]$

$$\begin{aligned}
E\{\tilde{c}[n]\} &= \frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| e^{j2\pi kn/N} E\{e^{j\varphi_k}\} = 0, \quad \forall n \\
&\Rightarrow E\{\tilde{c}_R[n]\} = 0 = E\{\tilde{c}_I[n]\}
\end{aligned} \tag{4.15}$$

A correlação cruzada entre as partes real e imaginária de $\tilde{c}[n]$ é dada por

$$\begin{aligned}
\tilde{h}[n_1, n_2] &= E\{\tilde{c}_R[n_1]\tilde{c}_I[n_2]\} \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| E\{\cos(\varphi_k + 2\pi kn_1/N) \sin(\varphi_z + 2\pi zn_2/N)\}
\end{aligned}$$

Utilizando (C.3) com $m = n_2 - n_1$ e substituindo (4.6.c) no resultado, tem-se

$$\tilde{h}[m] = \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \sin\left(\frac{2\pi k}{N} m\right) = 0 \tag{4.16}$$

onde, o somatório do produto entre uma seqüência par $S_n[k]$ e m períodos completos de uma seqüência ímpar (senóide) resulta em um valor nulo.

A função de correlação da parte real do processo é dada por

$$\begin{aligned}
\tilde{g}_R[n_1, n_2] &= E\{\tilde{c}_R[n_1]\tilde{c}_R[n_2]\} \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| E\{\cos(\varphi_k + 2\pi kn_1/N) \cos(\varphi_z + 2\pi zn_2/N)\}
\end{aligned}$$

Aplicando (C.1) com $m = n_2 - n_1$ e (4.6.c) na equação acima, tem-se

$$\begin{aligned}
\tilde{g}_R[m] &= \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \cos\left(\frac{2\pi k}{N} m\right) \\
&= \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \cos\left(\frac{2\pi k}{N} m\right) + j \tilde{h}[m] \\
&= \sigma^2 \text{IDFT}\{S_n[k]\} \\
&= \sigma^2 J_0(2\pi m T_s f_m)
\end{aligned} \tag{4.17}$$

onde foi utilizada a relação (3.15) para tempo discreto. Note que (4.16) foi utilizada na equação acima apenas como um artifício para evidenciar a transformada de Fourier discreta inversa.

A função de correlação da parte imaginária do processo é dada por

$$\begin{aligned}\tilde{g}_1[n_1, n_2] &= E\{\tilde{c}_1[n_1]\tilde{c}_1[n_2]\} \\ &= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| E\{\sin(\varphi_k + 2\pi kn_1/N) \sin(\varphi_z + 2\pi zn_2/N)\}\end{aligned}$$

Aplicando (C.2) com $m = n_2 - n_1$ e (4.6.c) na equação acima, tem-se

$$\tilde{g}_1[m] = \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \cos\left(\frac{2\pi k}{N} m\right) = \tilde{g}_R[m] = \sigma^2 J_0(2\pi m T_s f_m) \quad (4.18)$$

A função de correlação do processo complexo é dada por

$$\begin{aligned}\tilde{R}_c[n_1, n_2] &= E\{\tilde{c}[n_1]\tilde{c}^*[n_2]\} \\ &= E\{\tilde{c}_R[n_1]\tilde{c}_R[n_2] - j\tilde{c}_R[n_1]\tilde{c}_I[n_2] + j\tilde{c}_I[n_1]\tilde{c}_R[n_2] + \tilde{c}_I[n_1]\tilde{c}_I[n_2]\} \\ &= \tilde{g}_R[m] - j\tilde{h}[m] - j\tilde{h}[m] + \tilde{g}_I[m] \\ &= 2\tilde{g}_R[m] \\ \Rightarrow \tilde{R}_c[m] &= 2\sigma^2 J_0(2\pi m T_s f_m)\end{aligned} \quad (4.19)$$

Finalmente, da definição de $\varphi[k]$

$$E\{e^{j\varphi_{ik}} e^{-j\varphi_{jz}}\} = E\{e^{j\varphi_{ik}}\} E\{e^{-j\varphi_{jz}}\} = 0, \quad i \neq j \text{ e } \forall k, z$$

Segue desse resultado que a covariância entre dois processos $\tilde{c}_i[n]$ e $\tilde{c}_j[n]$ é dada por

$$\begin{aligned}\tilde{C}_{c_i c_j}[m] &= E\{\tilde{c}_i[n]\tilde{c}_j^*[n+m]\} - E\{\tilde{c}_i[n]\} E^*\{\tilde{c}_j[n]\} \\ &= \frac{1}{N^2} \sum_{k=0}^{M-1} \sum_{z=0}^{M-1} |S_T[k]| |S_T[z]| e^{j\frac{2\pi k}{M}n} e^{-j\frac{2\pi z}{M}(n+m)} E\{e^{j\varphi_{ik}} e^{-j\varphi_{jz}}\} = 0, \quad i \neq j\end{aligned} \quad (4.20)$$

4.2.2 MÉDIAS TEMPORAIS

Para os cálculos que seguem considere a definição de operador média temporal em (A.6).

O valor médio da parte real de uma função amostra do processo é dado por

$$\begin{aligned}
\langle [\tilde{c}_R[n]] \rangle &= \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=0}^{N-1} \left(\frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| \cos(\varphi_k + 2\pi kn/N) \right) \\
&= \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| \frac{1}{N} \sum_{n=0}^{N-1} \cos(\varphi_k + 2\pi kn/N) \right) \\
&= \frac{1}{N} |S_T[0]| \cos \varphi_0 = 0
\end{aligned} \tag{4.21}$$

Realizando procedimento semelhante pode-se obter

$$\langle [\tilde{c}_I[n]] \rangle = \frac{1}{N} |S_T[0]| \sin \varphi_0 = 0 \tag{4.22}$$

$$\langle [\tilde{c}[n]] \rangle = \langle [\tilde{c}_R[n]] \rangle + j \langle [\tilde{c}_I[n]] \rangle = 0 \tag{4.23}$$

A função de autocorrelação temporal da parte real de uma função amostra é dada por

$$\begin{aligned}
\tilde{g}_R[m] &= \langle [\tilde{c}_R[n] \tilde{c}_R[n+m]] \rangle \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} \cos(\varphi_k + 2\pi kn/N) \cos(\varphi_z + 2\pi z(n+m)/N) \right)
\end{aligned}$$

Para $k \neq z$ esse limite será nulo, pois se trata do valor médio temporal do produto entre duas cossenóides com frequências diferentes. Já para $k = z$ o limite será

$$\lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} \cos\left(\varphi_k + \frac{2\pi k}{N} n\right) \cos\left(\varphi_k + \frac{2\pi k}{N} n + \frac{2\pi k}{N} m\right) \right) = \frac{1}{2} \cos\left(\frac{2\pi k}{N} m\right)$$

Substituindo esse resultado na equação inicial

$$\begin{aligned}
\tilde{g}_R[m] &= \frac{1}{2N^2} \sum_{k=0}^{N-1} |S_T[k]|^2 \cos\left(\frac{2\pi k}{N} m\right) \\
&= \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \cos\left(\frac{2\pi k}{N} m\right) = \tilde{g}_R[m]
\end{aligned} \tag{4.24}$$

Com procedimento semelhante pode-se obter

$$\tilde{g}_I[m] = \frac{1}{2N^2} \sum_{k=0}^{N-1} |S_T[k]|^2 \cos\left(\frac{2\pi k}{N} m\right) = \tilde{g}_I[m] \tag{4.25}$$

A correlação cruzada entre as partes real e imaginária de uma função amostra é dada por

$$\begin{aligned}
\tilde{h}[m] &= \langle [\tilde{c}_R[n] \tilde{c}_I[n+m]] \rangle \quad (4.26) \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} \cos(\varphi_k + 2\pi kn/N) \text{sen}(\varphi_z + 2\pi z(n+m)/N) \right) \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} |S_T[k]|^2 \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} \cos(\varphi_k + 2\pi kn/N) \text{sen}(\varphi_k + 2\pi kn/N + 2\pi km/N) \right) \\
&= \frac{1}{N^2} |S_T[0]|^2 \cos \varphi_0 \text{sen} \varphi_0 + \frac{1}{N^2} \sum_{k=1}^{N-1} |S_T[k]|^2 \text{sen}(2\pi km/N) \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} \cos^2(\varphi_k + 2\pi kn/N) \right) \\
&= \frac{1}{2N^2} \sum_{k=0}^{N-1} |S_T[k]|^2 \text{sen}(2\pi km/N) \\
&= \sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] \text{sen}\left(\frac{2\pi k}{N} m\right) = \tilde{h}[m]
\end{aligned}$$

A função de autocorrelação temporal é dada por

$$\begin{aligned}
\tilde{R}_c[m] &= \langle [\tilde{c}[n] \tilde{c}^*[n+m]] \rangle \quad (4.27) \\
&= \langle [(\tilde{c}_R[n] \tilde{c}_R[n+m] - j \tilde{c}_R[n] \tilde{c}_I[n+m] + j \tilde{c}_I[n] \tilde{c}_R[n+m] + \tilde{c}_I[n] \tilde{c}_I[n+m])] \rangle \\
&= \tilde{g}_R[m] - j \tilde{h}[m] - j \tilde{h}[m] + \tilde{g}_I[m] \\
&= 2\tilde{g}_R[m] = 2\tilde{g}_R[m] = \tilde{R}_c[m]
\end{aligned}$$

A covariância entre duas funções amostras é dada por

$$\begin{aligned}
\tilde{C}_{c_i, c_j}[m] &= \langle [\tilde{c}_i[n] \tilde{c}_j^*[n+m]] \rangle - \langle [\tilde{c}_i[n]] \rangle \langle [\tilde{c}_j^*[n]] \rangle \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} \sum_{z=0}^{N-1} |S_T[k]| |S_T[z]| e^{j(\varphi_{i,k} - \varphi_{j,z})} e^{-j \frac{2\pi z}{N} m} \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} e^{-j \frac{2\pi n}{N} (k-z)} \right) \\
&= \frac{1}{N^2} \sum_{k=0}^{N-1} |S_T[k]|^2 e^{j(\varphi_{i,k} - \varphi_{j,z})} e^{-j \frac{2\pi k}{N} m} \\
&= 2\sigma^2 \frac{1}{N} \sum_{k=0}^{N-1} S_n[k] e^{j(\varphi_{i,k} - \varphi_{j,k})} e^{-j \frac{2\pi k}{N} m}, \quad i \neq j \quad (4.28)
\end{aligned}$$

Pode ser mostrado numericamente (veja resultados de simulação) que $\tilde{C}_{c_i, c_j}[m]$ é aproximadamente nulo para valores práticos de N . Como conseqüência, duas funções amostras são não correlacionadas no tempo.

Foi verificado que as médias estatísticas e temporais do modelo são iguais. Além disso, em todas as médias temporais calculadas, com exceção de (4.28), no resultado final não aparecem variáveis aleatórias, o que torna os resultados válidos para qualquer função amostra do processo. Conseqüentemente equação (A.7) é válida para valor médio, autocorrelação e correlação cruzada entre as partes real e imaginária, implicando ergodicidade com respeito a estas médias.

4.3 ADAPTAÇÃO AO MODELO DE PROPAGAÇÃO TRIDIMENSIONAL DE AULIN

No capítulo anterior foi mencionado que o modelo de propagação por espalhamento de Aulin generaliza o modelo de Clarke e adiciona a este os efeitos da propagação não horizontal das componentes de onda. Mais especificamente, os ângulos aleatórios de elevação, presentes nas componentes de onda, mudam a função de autocorrelação e conseqüentemente a densidade espectral de potência do processo. Para também adicionar esse efeito ao simulador proposto (que será denominado “modelo proposto tridimensional”), é suficiente substituir em (4.9) a função $|S_T[k]|$ (raiz quadrada da DEP do processo bidimensional) por $|S'_T[k]|$ (raiz quadrada da DEP do processo tridimensional), onde, da mesma forma que no modelo bidimensional (apenas alterando a notação), tem-se

$$\begin{aligned} |S'_T[k]| &= \frac{1}{T_s} |S'_T(kT_f)| = \frac{1}{T_s} \sqrt{2\sigma^2 T S'_n(kT_f)} \\ &= \sqrt{2\sigma^2 \frac{N}{T_s} S'_n(kT_f)} = \sqrt{2\sigma^2 N S'_n[k]} \end{aligned} \quad (4.29)$$

e

$$|S'_T[k]| = \begin{cases} 0, & k = 0 \\ \sqrt{\left(\frac{2\sigma^2 N}{T_s}\right) S'_n(kT_f)}, & 1 \leq k \leq K_m \\ 0, & K_m + 1 \leq k \leq N - 1 - K_m \\ |S'_T[N - k]|, & N - K_m \leq k \leq N - 1 \end{cases} \quad (4.30)$$

onde $S'_n(f)$ é dada por (3.30).

Substituindo $S_n[k]$ por $S'_n[k]$ em (4.17) (linha 3) e observando (4.19) (linha 4), percebe-se que a função de autocorrelação do modelo será igual a $IDFT\{S'_n[k]\}$. Conseqüentemente, de (3.30) e (3.27), é possível concluir que a função de autocorrelação do modelo proposto tridimensional será igual a função de autocorrelação teórica apresentada pelo modelo de Aulin. Realizando procedimentos semelhantes, pode-se mostrar que as propriedades estatísticas desse modelo computacional concordam com as propriedades estatísticas do modelo teórico de Aulin.

Agora considerando a densidade de probabilidade para o ângulo de elevação sugerida em [46] e definida em (3.31), tem-se

$$|S'_T[k]| = \begin{cases} 0, & k = 0 \\ \sqrt{\left(\frac{2\sigma^2 N}{T_s}\right) \frac{1}{2\pi f_m \text{sen}\beta_{\max}} \left[\frac{\pi}{2} - \arcsen \frac{2\cos^2\beta_{\max} - 1 - \left(\frac{kT_f}{f_m}\right)^2}{1 - \left(\frac{kT_f}{f_m}\right)^2} \right]}, & 1 \leq k < K_c \\ \sqrt{\left(\frac{2\sigma^2 N}{T_s}\right) \frac{1}{2f_m \text{sen}\beta_{\max}}}, & K_c \leq k \leq K_m \\ 0, & K_m + 1 \leq k \leq N - 1 - K_m \\ |S'_T[N - k]|, & N - K_m \leq k \leq N - 1 \end{cases} \quad (4.31)$$

Onde

$$K_c = \left\lceil \frac{f_m \cos\beta_{\max}}{f_s} N \right\rceil \quad (4.32)$$

Substituindo (4.31) em (4.9), tem-se os coeficientes de transmissão discretos do modelo proposto tridimensional

$$\begin{aligned} c'[n] &= IDFT \left\{ |S'_T[k]| e^{j\phi_k} \right\} \\ &= \frac{1}{N} \sum_{k=0}^{N-1} |S'_T[k]| e^{j\phi_k} e^{j2\pi kn/N}, \quad n = 0, 1, \dots, N-1 \end{aligned} \quad (4.33)$$

onde β_{\max} deve ser incluído como parâmetro de entrada do modelo.

CAPÍTULO 5

RESULTADOS DE SIMULAÇÃO

Neste capítulo são apresentados os procedimentos necessários para simulação computacional de canal Rayleigh e Rice, assim como os resultados de simulação do modelo proposto. Uma comparação entre o modelo proposto e outros dois modelos é realizada no final do capítulo.

Uma sugestão para implementação do simulador proposto, em linguagem MATLAB[®], pode ser encontrada no APÊNDICE D, algoritmo “mpath_sim_f2”. São parâmetros de entrada do algoritmo: b , f_m , T_s e N , onde $b = 2\sigma^2$. A matriz de saída cn contém em cada linha uma componente multipercurso. O número de componentes multipercurso a serem geradas é dado pelo comprimento do vetor de entrada b . A Figura 5.1 ilustra um exemplo de envoltória gerada pelo algoritmo. O gráfico ilustra somente os primeiros 1,8 segundos da envoltória. Neste exemplo, uma frequência de propagação de 836 MHz e uma velocidade do móvel de 24,14 km/h produziram esse valor de f_m .

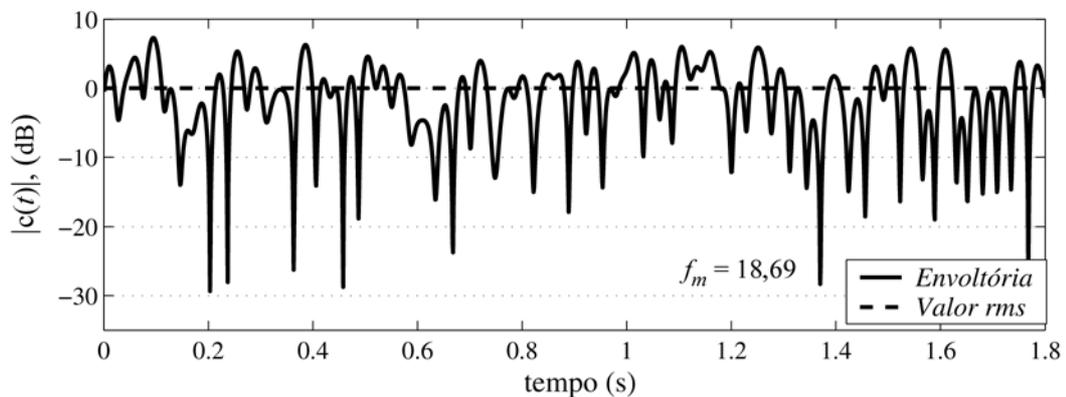


Figura 5.1: Um exemplo de envoltória gerada a partir do modelo proposto. Parâmetros de simulação: $b = 1$, $f_m = 18,69$ Hz, $T_s = 1$ ms e $N = 2^{18}$.

5.1 TEMPO DE EXECUÇÃO DO MODELO PROPOSTO

O tempo de execução do simulador de canal é de especial importância, pois recursos computacionais disponíveis são limitados. Para algumas aplicações, como por exemplo simulação Monte Carlo, o simulador de canal pode ser requisitado centenas de vezes em uma mesma simulação, onde o número de amostras utilizadas pode ser elevado, exigindo um elevado esforço computacional e tempo de execução. Para minimizar o tempo gasto nestas simulações é desejável que o simulador de canal seja capaz de gerar os coeficientes de transmissão no menor tempo possível.

Devido ao uso da IFFT no modelo proposto, deve-se atentar para o número de amostras N utilizadas. Se N for, por exemplo, um número primo, então o cálculo da IFFT pode se tornar dezenas de vezes mais lento. Um algoritmo adaptativo de alto desempenho para o cálculo da transformada rápida de Fourier foi proposto por Matteo Frigo e Steven G. Johnson [19], o qual está baseado nos algoritmos Cooley-Tukey [18]. O TE desse algoritmo depende do comprimento da seqüência. Para seqüências cujo comprimento é uma potência de dois ou tem pequenos fatores primos, o cálculo é feito rapidamente. Já para seqüências cujo comprimento é um número primo ou tem fatores primos grandes o cálculo se torna mais lento (consulte Anexo A, item Algorithm, 4º parágrafo). Esse algoritmo é de domínio público e o *software* MATLAB® (versão 6.0 ou superior), hoje utilizado pela grande maioria dos pesquisadores nesta área, faz uso do mesmo.

Uma maneira simples (empírica) de evitar que N venha a ser um número primo, ou que venha a ter fatores primos grandes é transformar seu valor em um múltiplo de 10^4 (considerando que os valores de interesse para N estão entre 10^4 e 10^6), ou seja,

$$N_t = \left\lceil \frac{N}{10^4} \right\rceil \times 10^4 = k \times 10^4$$

Como $10^4 = (2 \times 5)^4$ tem 8 fatores primos, então o número de fatores primos de N_t será igual a: (número de fatores primos de k) + 8. Para N entre 100 mil e 1 milhão (faixa de valores comumente utilizada em simulações), k irá variar de 10 a 100 e o maior fator primo nesse intervalo será igual a 97.

A transformação acima é uma quantização do número de amostras e deve ocorrer no interior do algoritmo do simulador, transparente ao usuário. Em outras palavras, N_t coeficientes de transmissão são requisitados ao simulador que calcula N_t coeficientes, mas devolve somente N coeficientes, sem prejuízo para as propriedades dos coeficientes de transmissão.

A Figura 5.2.a ilustra o processo de quantização das amostras. O tempo de execução médio normalizado (ET_{av}) apresentado pelo modelo está ilustrado na Figura 5.2.b. A curva de tempo de execução médio normalizado para número de amostras em potência de 2 (ET_{avp2}) (supostamente o melhor caso) serve como parâmetro para comparação. Verifica-se que a curva de ET_{av} acompanha a curva ET_{avp2} com alguns picos em determinados pontos.

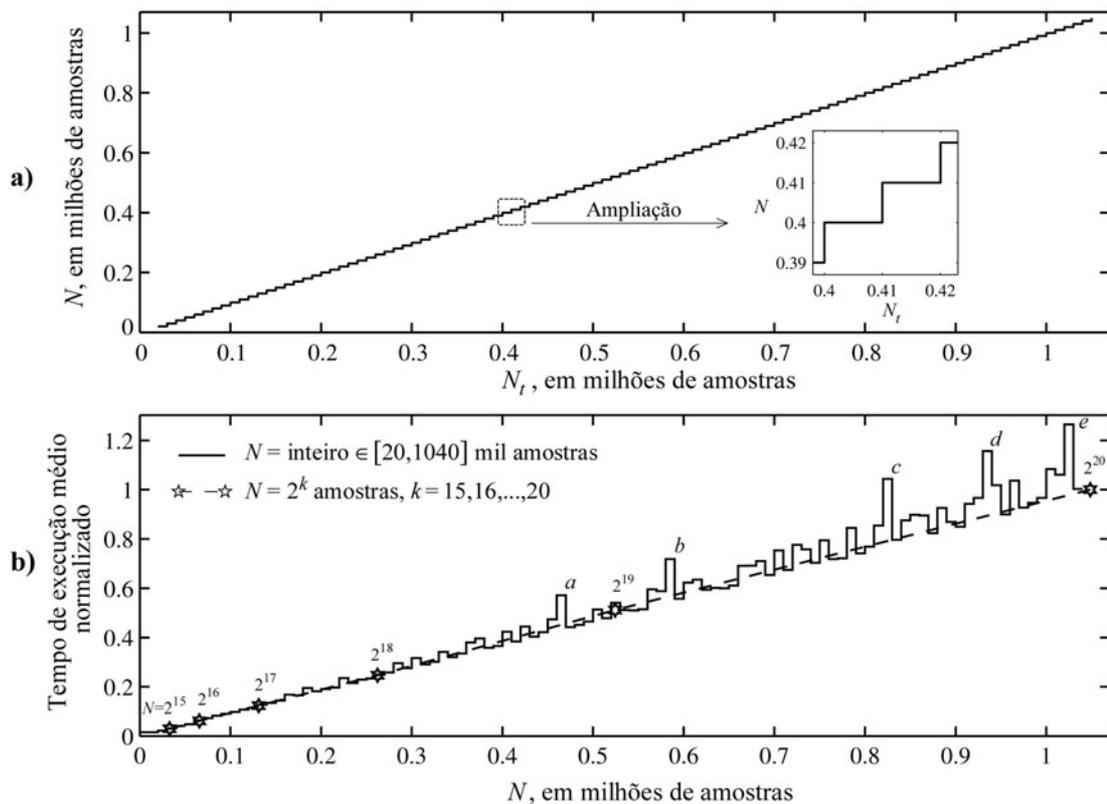


Figura 5.2: a) Quantização do número de amostras; b) Tempo de execução normalizado.

Média sobre 30 simulações com um conjunto de 6 componentes multipercurso em cada uma.

Esse resultado ainda pode ser melhorado com uma pequena alteração no quantizador

da Figura 5.2.a. Seja $N[c]$ o valor de N no ponto c ilustrado na Figura 5.2.b. A figura ilustra que é mais rápido calcular a IFFT para $N[c]+10^4$ amostras (degrau seguinte ao ponto c) a calcular a IFFT de $N[c]$ amostras. O mesmo acontece com $N[a]$, $N[b]$, $N[d]$ e $N[e]$. A Tabela 5.1 mostra que há pelo menos um fator primo bem maior que os demais fatores (tipicamente 2 e 5) presentes no número de amostras desses pontos. O quantizador pode identificar esses pontos e evitá-los, para também evitar os picos de ET_{av} .

Tabela 5.1: Fatores primos máximos nos pontos a , b , c , d e e .

	Número de amostras (em milhares)	Maior fator primo
$N[a]$	470	47
$N[b]$	590	59
$N[c]$	830	83
$N[d]$	940	47
$N[e]$	1030	103

A Figura 5.3 ilustra um algoritmo em pseudolinguagem de um quantizador que transforma N em um número N_t que tenha todos os fatores primos menores ou iguais a 13. Caso N seja potência de dois, não há transformação. Caso contrário, N_t assume o menor dentre os dois números seguintes: o menor inteiro maior que N que seja potência de dois ou o menor inteiro maior que N que seja múltiplo de 10^4 e tenha todos os fatores primos menores ou iguais a 13 (veja APÊNDICE D, algoritmo “mpath_sim_f2” para implementação do simulador com esse quantizador).

A Figura 5.4.a ilustra o quantizador cuja algoritmo foi apresentado na Figura 5.3. O ET_{av} com o uso desse quantizador está ilustrado na Figura 5.4.b. Verifica-se agora que o ET_{av} além de acompanhar a curva de ET_{avp2} , não apresenta os picos ilustrados na Figura 5.2.b. O resultado é um simulador que pode ser considerado de baixo tempo de execução independentemente do valor assumido por N . Esse resultado pode ser facilmente estendido para faixas de valores de N maiores que 2^{20} .

```

Se  $N = (\text{número potência de dois})$  então
     $N_t = N;$ 
Senão
     $N_t = \lceil N/1e4 \rceil \times 1e4;$ 
    fator_max = max(factor( $N_t$ ));
Enquanto fator_max > 13 faça
     $N_t = N_t + 1e4;$ 
    fator_max = max(factor( $N_t$ ));
Fim enquanto
Se  $2^{\lceil \log_2(N) \rceil} < N_t$  então
     $N_t = 2^{\lceil \log_2(N) \rceil};$ 
Fim se
Fim se

```

Figura 5.3: Algoritmo em pseudolinguagem do quantizador utilizado no modelo de canal.

Notação: factor(y) = função que devolve os fatores primos de y;

max(x) = calcula o maior elemento em x.

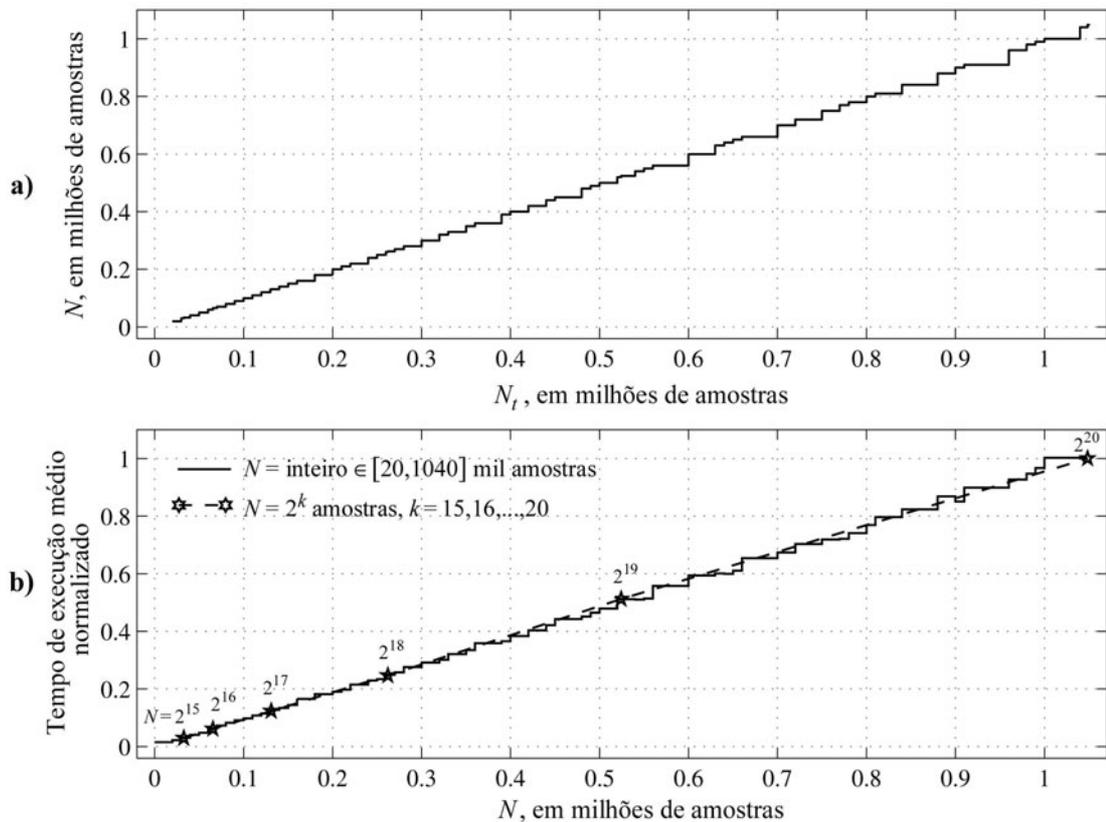


Figura 5.4: a) Quantização; b) ET_{av} e ET_{avp2} . Média sobre 30 simulações com um conjunto de 6 componentes multipercurso em cada simulação.

5.2 PROPRIEDADES ESTATÍSTICAS DO MODELO PROPOSTO OBTIDAS NUMERICAMENTE

Nesta seção, serão apresentados alguns resultados numéricos de médias temporais obtidos a partir do modelo proposto (algoritmo “mpath_sim_f2”), tomando como referência as médias estatísticas de um canal com desvanecimento, apresentadas em (3.14).

5.2.1 DENSIDADES DE PROBABILIDADE

A Figura 5.5 ilustra as densidades de probabilidade teórica e obtidas numericamente através de simulação. Os resultados indicam um bom ajuste entre as curvas teóricas e simuladas, nos quatro casos. Vale lembrar que o ajuste será tão melhor quanto maior for o número de pontos simulados.

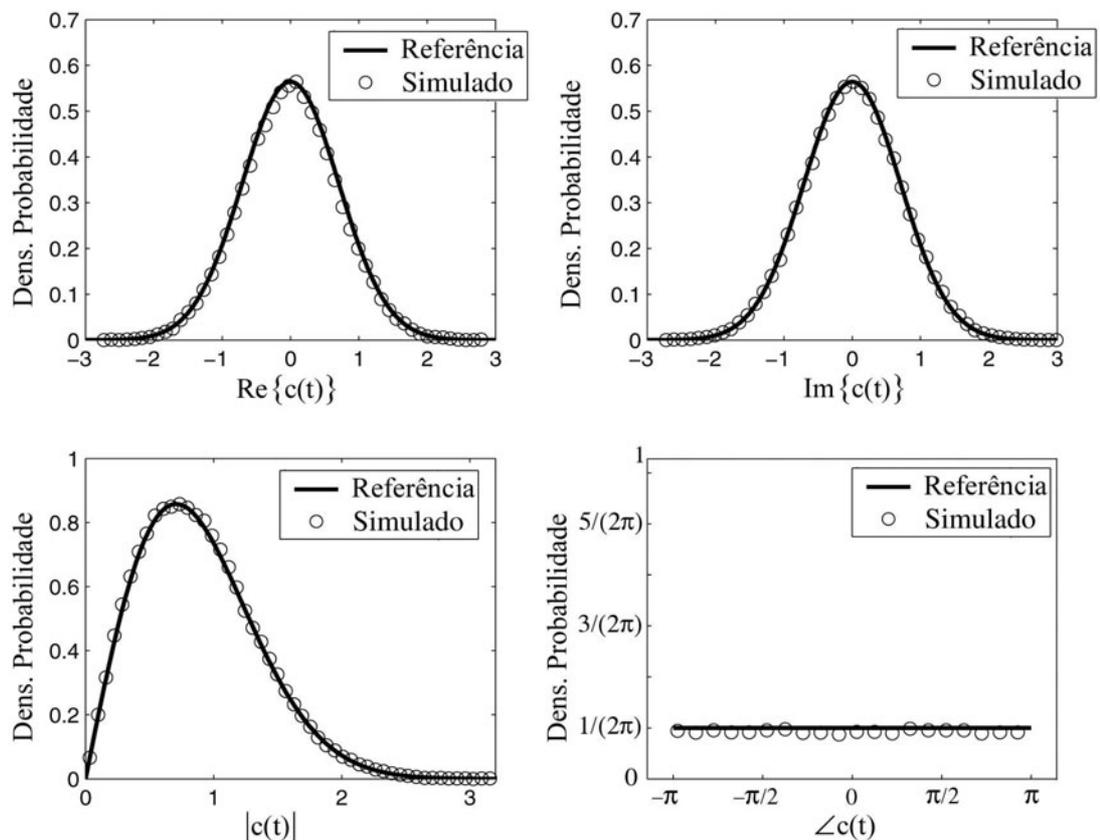


Figura 5.5: Curvas teóricas e simuladas de densidades de probabilidade; $f_m = 18,69$ Hz, $T_s = 1\text{ms}$ e $N = 2^{18}$.

5.2.2 TAXA DE OCORRÊNCIA DE NULOS

Seja uma simulação com $b = 1$, $f_m = 30$ Hz, $T_s = 1$ ms e $N = 2^{18}$. Para uma frequência de propagação f_c igual a 2 GHz, tem-se uma velocidade do móvel igual a 4,5 m/s e um comprimento de onda igual a 15 cm. Nesse caso, os nulos devem ocorrer espaçados por aproximadamente $\lambda/2 = 7,5$ cm [4]. Já a taxa aproximada de ocorrência de nulos, dada em (3.19), deve estar próxima de 60 nulos/s.

A Figura 5.6 ilustra o resultado de uma simulação com esses parâmetros. O gráfico mostra o que poderia ser a envoltória em dB de um sinal recebido por um móvel com um deslocamento de 30λ no intervalo de 1 segundo ($v = 30\lambda/s = 4,5$ m/s). Verifica-se a ocorrência aproximada de um nulo a cada $\frac{1}{2}$ comprimento de onda. Mais precisamente ocorreram 49 nulos/s, resultando em 1 nulo a cada $0,61 \lambda$. Resultado (numérico) semelhante pode ser obtido com o modelo de Clarke (1 nulo a cada $0,6 \lambda$) e com os modelos modificados de Jakes. Mais do que isso, a ocorrência de 1 nulo a cada $0,62 \lambda$ foi verificada experimentalmente por meio de medidas de campo realizadas em [45]. Pode-se concluir a partir desses fatos que na realidade dois nulos subseqüentes ocorrem separados por aproximadamente $0,6 \lambda$, implicando a coerência do resultado obtido a partir do modelo proposto.

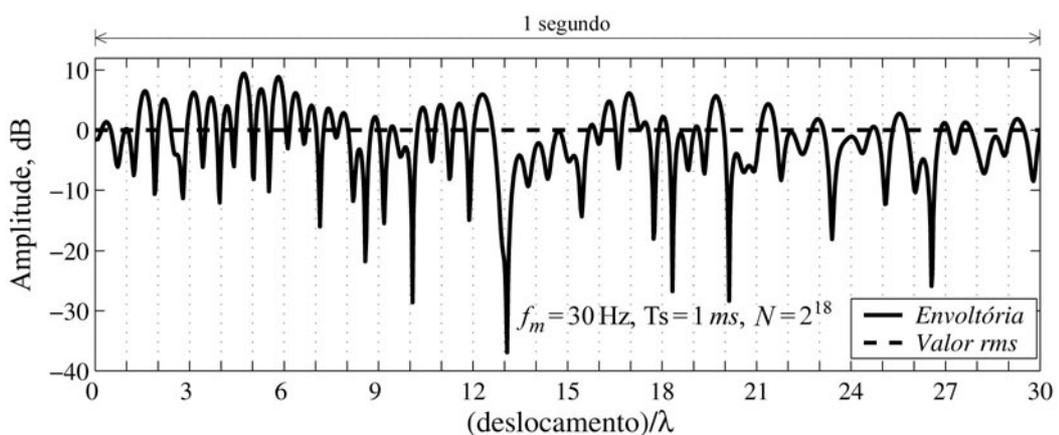


Figura 5.6: Taxa de ocorrência de nulos.

5.2.3 TAXA DE CRUZAMENTO DE NÍVEL E DURAÇÃO MÉDIA DOS DESVANECIMENTOS

Em comunicações móveis, valores típicos de máximo deslocamento Doppler, com frequência de propagação igual a 1,8 GHz (sistemas de terceira geração), estão entre 7 Hz e 200 Hz. O primeiro caso reproduz a situação onde o móvel poderia ser um pedestre caminhando ($v = 4,2$ km/h). Já o segundo caso reproduz a situação onde o móvel poderia ser um veículo em alta velocidade ($v = 120$ km/h). Nesta faixa de frequência Doppler pode ser de interesse saber qual o número de vezes que a envoltória do sinal recebido cruza um determinado nível, ao sofrer um desvanecimento, ou quanto tempo a envoltória fica abaixo desse nível quando sofre esse desvanecimento. A taxa de cruzamento de nível e a duração média dos desvanecimentos respectivamente, contêm estas informações.

Para obter numericamente a taxa de cruzamento de nível e a duração média dos desvanecimentos foi implementado o procedimento “afd_nr” (veja APÊNDICE D). A simulação foi realizada com $N=1,5 \times 10^6$ e considerando os três pares de valores para f_m e T_s : (7 Hz, 200 μ s), (60 Hz, 20 μ s) e (200 Hz, 20 μ s). O resultado obtido foi um perfeito ajuste entre as curvas teóricas e simuladas, como mostra a Figura 5.7, com exceção do ponto -40 dB, que poderia ser melhorado com o aumento do número de amostras simuladas N .

5.2.4 CORRELAÇÃO ENTRE COMPONENTES MULTIPERCURSO

A Figura 5.8 ilustra os resultados de correlação entre 4 funções amostras geradas pelo modelo, que podem representar 4 componentes multipercurso, com $b = 1$ para todas as funções e τ variando de 0 a 120 ms. Nota-se na figura que a faixa aproximada de variação da correlação é $\pm 0,02$. Em outras palavras, para o intervalo de tempo considerado a correlação não assume valor maior que 2% de seu valor máximo. Desta forma, as componentes multipercurso podem ser consideradas não correlacionadas.

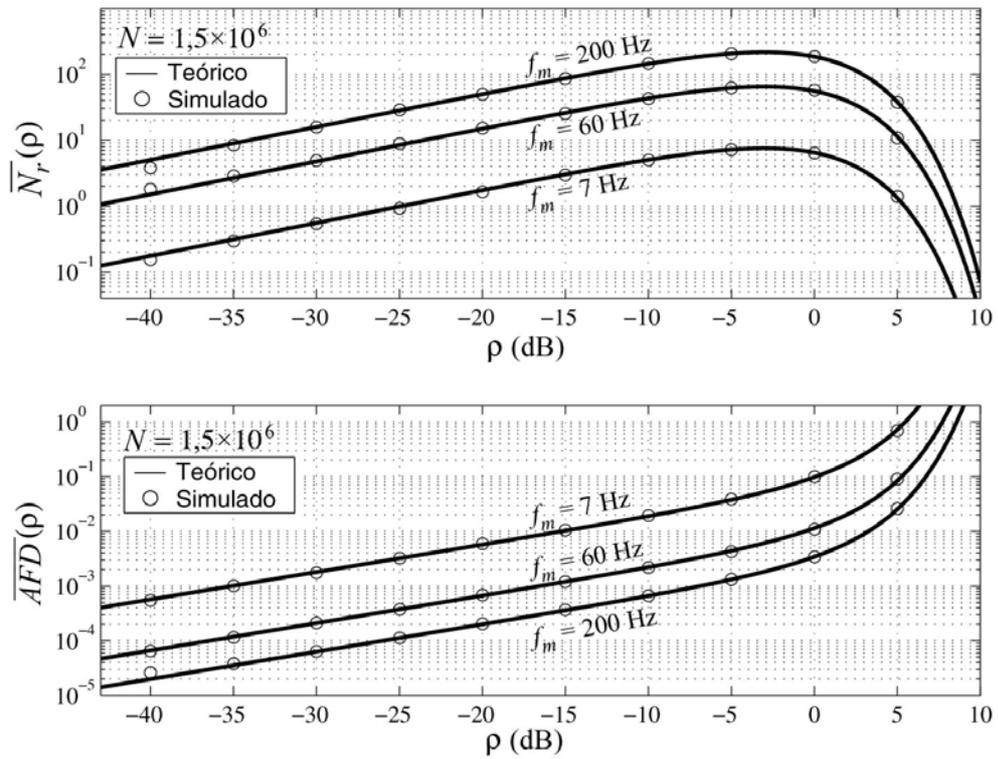


Figura 5.7: Taxa de cruzamento de nível e duração média dos desvanecimentos.

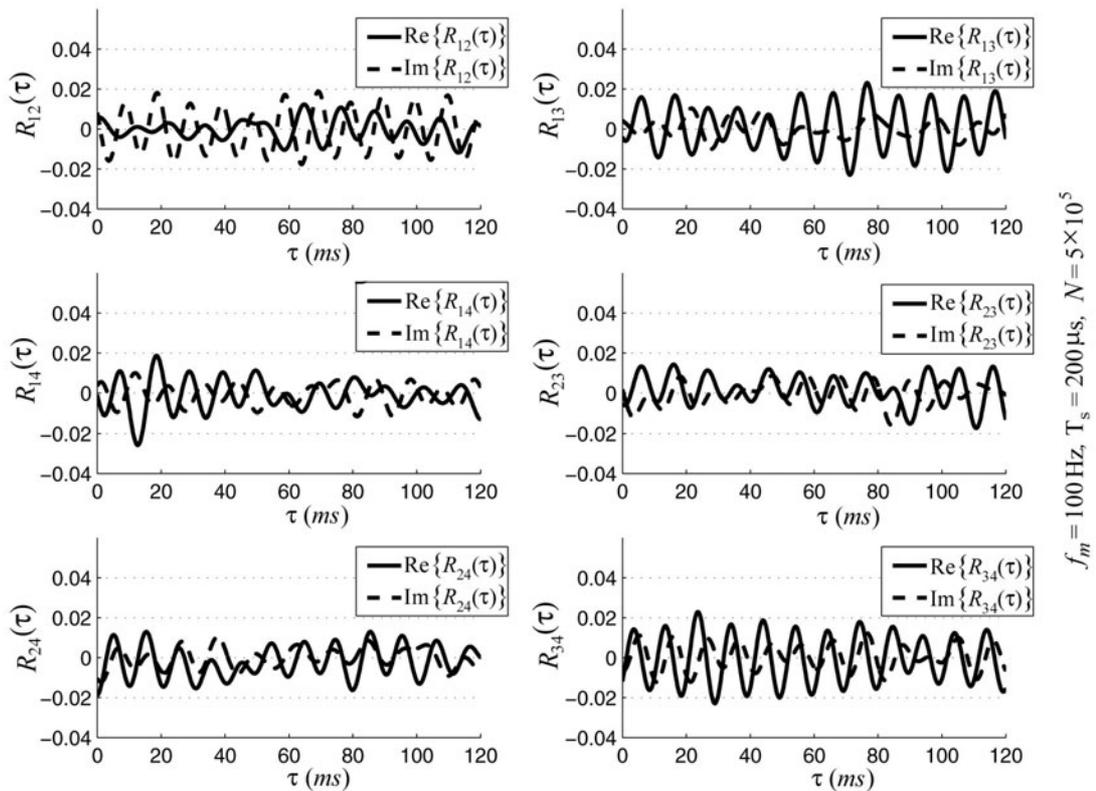


Figura 5.8: Correlação cruzada entre 4 componentes multipercursos.

5.2.5 AUTOCORRELAÇÃO

A Figura 5.9 ilustra os resultados numéricos para as partes real e imaginária da autocorrelação. A Figura 5.10 ilustra a autocorrelação da parte real e a Figura 5.11 a autocorrelação da parte imaginária. Mais uma vez verifica-se uma boa concordância dos resultados numéricos com os valores teóricos, pois há um perfeito ajuste entre as curvas de Bessel e as curvas simuladas.

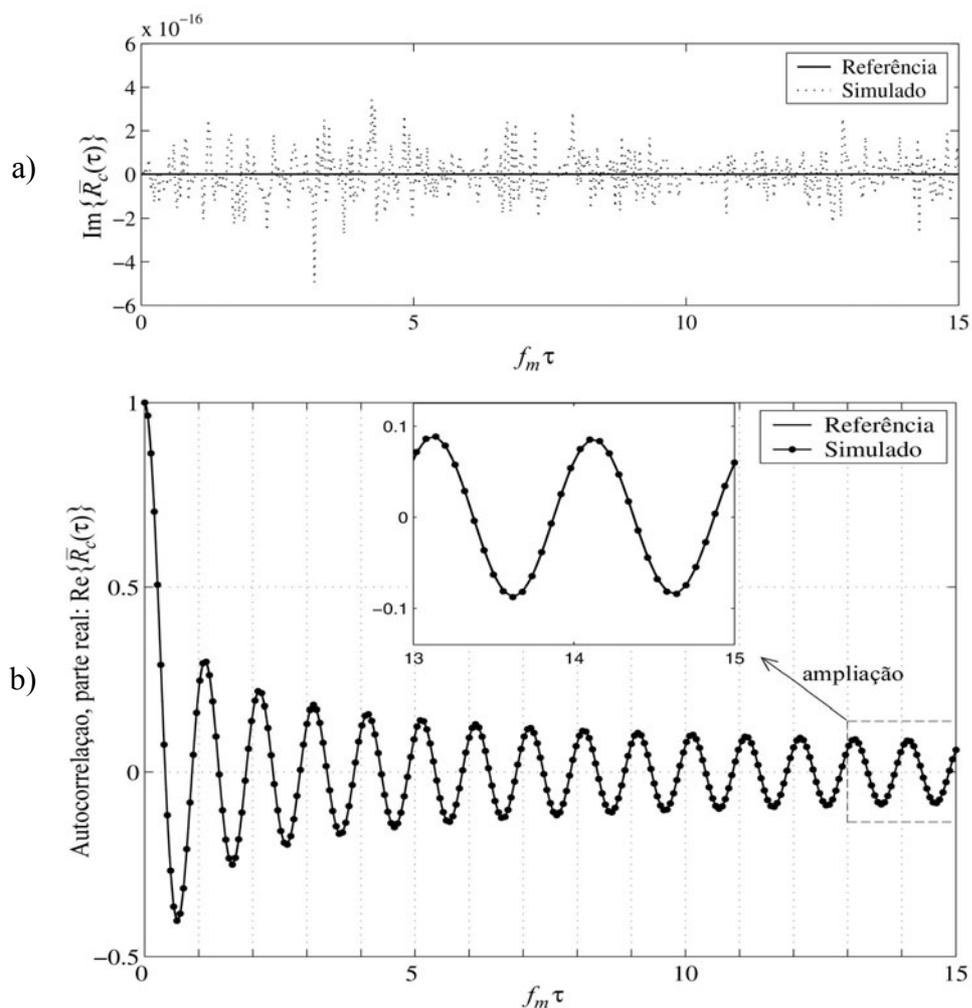


Figura 5.9: a) parte imaginária da autocorrelação e b) parte real da autocorrelação; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.

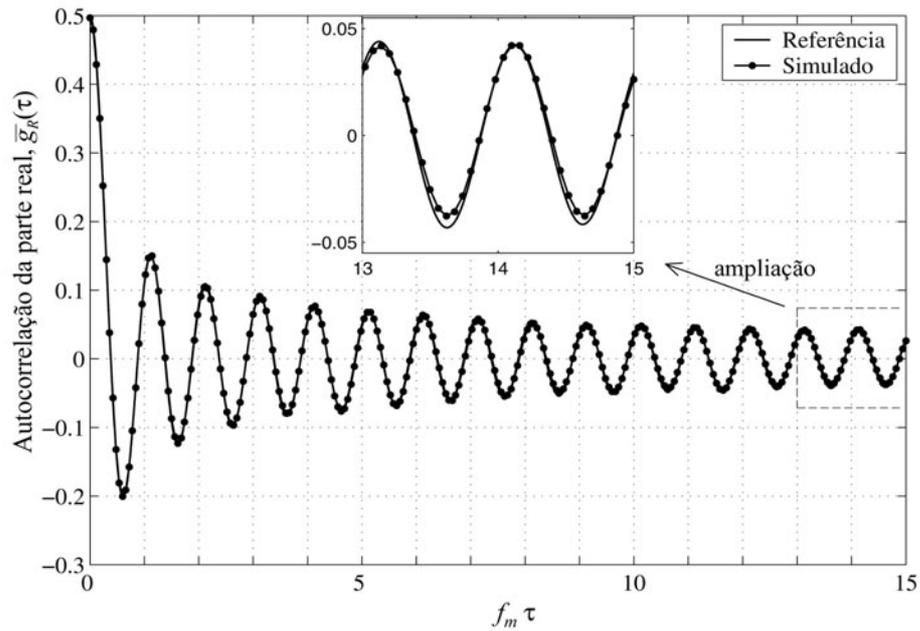


Figura 5.10: Autocorrelação da parte real; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.

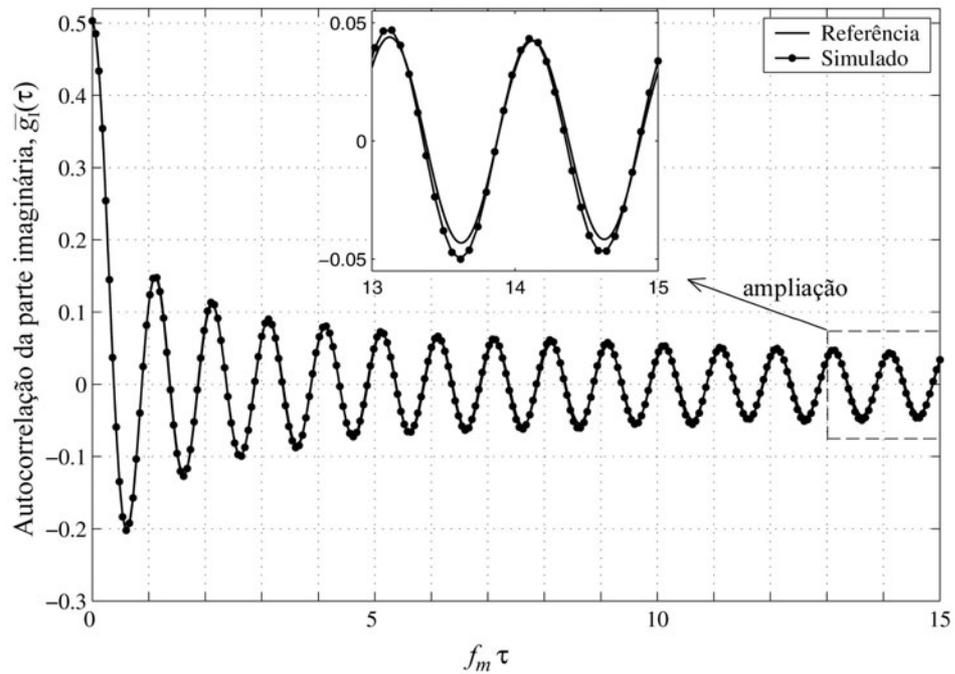


Figura 5.11: Autocorrelação da parte imaginária; $b = 1$, $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$.

5.2.6 CORRELAÇÃO ENTRE AS PARTES REAL E IMAGINÁRIA

A Figura 5.12 ilustra a correlação obtida numericamente entre as partes real e

imaginária de uma função amostra (parâmetros de simulação iguais ao do item anterior). Note que os valores são suficientemente pequenos para que $\text{Re}\{\tilde{c}[n]\}$ e $\text{Im}\{\tilde{c}[n]\}$ possam ser consideradas não correlacionadas.

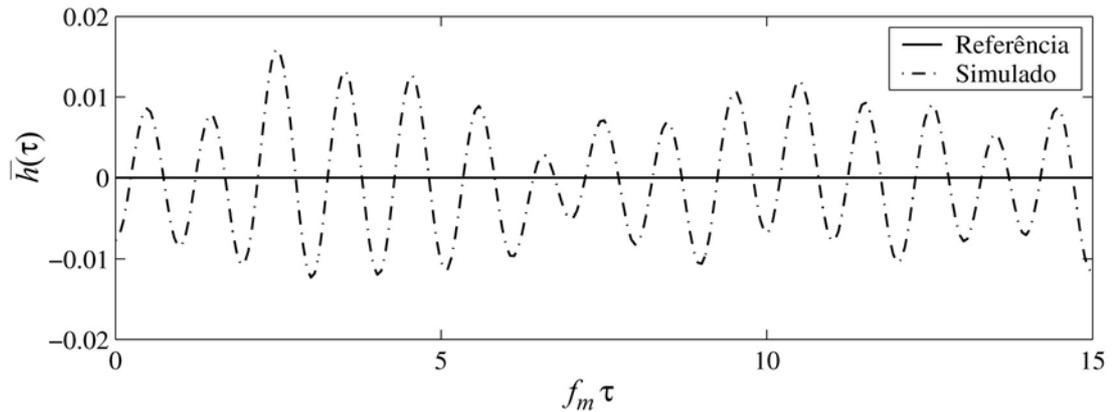


Figura 5.12: Correlação entre as partes real e imaginária.

5.3 SIMULANDO COMPONENTES MULTIPERCURSO CORRELACIONADAS

A Figura 5.13 ilustra as envoltórias de duas componentes multipercurso ($c_1(t)$ e $c_3(t)$) obtidas por meio da relação (3.81), com correlação cruzada normalizada igual a 0,7 (gráfico superior) e 0,1 (gráfico inferior), onde $c_1(t)$ e $c_2(t)$ foram obtidas do modelo proposto com $f_m = 100$ Hz, $T_s = 300$ μ s, $N = 200.000$ e $(2\sigma_1^2) = (2\sigma_2^2) = (2\sigma_3^2) = 1$. Por inspeção (na envoltória), a correlação entre as formas de onda é elevada no gráfico superior e aparenta não existir no gráfico inferior, conforme esperado. Os valores de correlação obtidos numericamente são: $(0,7009 + j0,0224)$ para $\Psi_{1,3} = 0,7$ e $(0,1024 + j0,0313)$ para $\Psi_{1,3} = 0,1$.

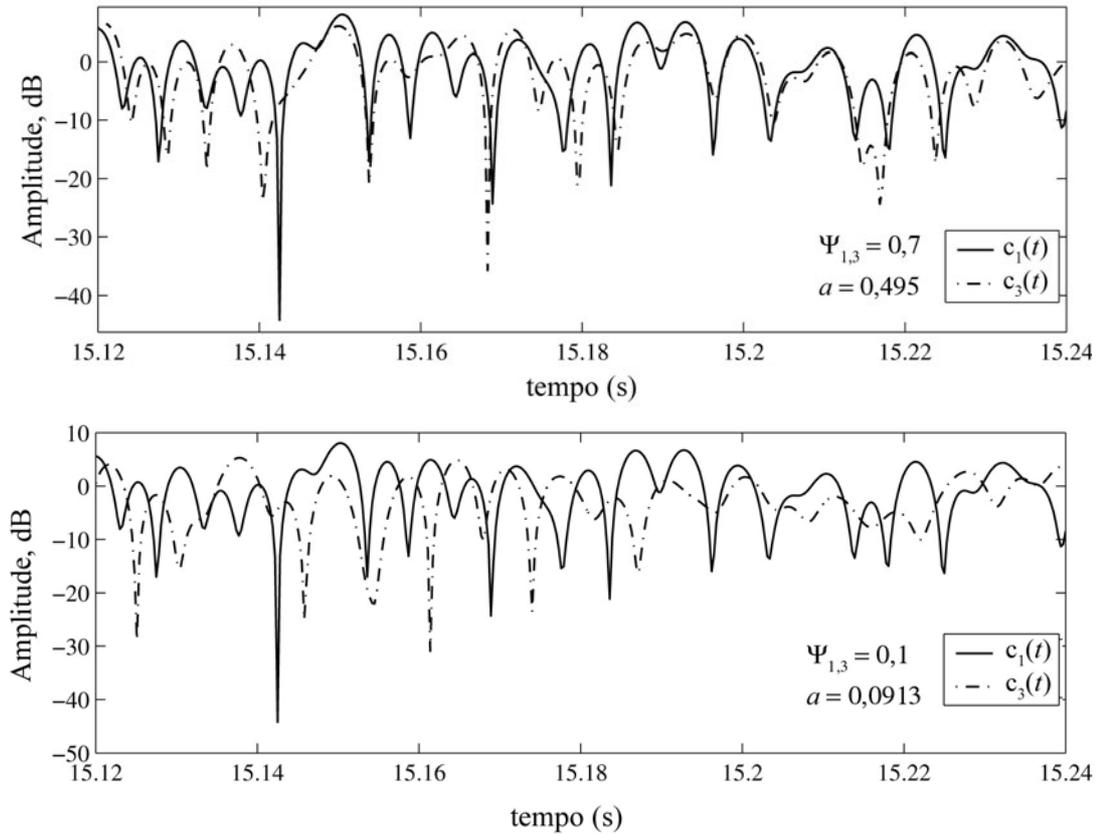


Figura 5.13: Envoltória de duas componentes multipercurso com correlação cruzada normalizada igual a 0,7 (gráfico superior) e 0,1 (gráfico inferior).

5.3.1 MODELO DE CANAL EM SISTEMAS COM MODULAÇÃO MULTIPORTADORA

O método apresentado no item 3.6 (página 68) pode ser utilizado para modelar um canal com desvanecimento Rayleigh em um sistema com modulação multiportadora. Nesse caso a correlação entre os coeficientes de transmissão da n -ésima e m -ésima subportadora é dada por [65]

$$\Psi_h^{n,m} = \frac{1 + j(n-m)\Delta f_n}{1 + (n-m)^2 \Delta f_n^2} \quad (5.1)$$

onde $\Delta f_n = \left(\frac{\Delta f}{B_c}\right)$, Δf é o espaçamento em frequência (considerado constante) entre duas subportadoras subsequentes e B_c a banda de coerência do canal.

De (5.1), a matriz de correlação dos coeficientes de transmissão para um sistema com L subportadoras é dada por

$$\Psi_h = \begin{bmatrix} 1 & \frac{1-j\Delta f_n}{1+\Delta f_n^2} & \dots & \frac{1-j(L-1)\Delta f_n}{1+(L-1)^2\Delta f_n^2} \\ \frac{1+j\Delta f_n}{1+\Delta f_n^2} & 1 & \dots & \frac{1-j(L-2)\Delta f_n}{1+(L-2)^2\Delta f_n^2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1+j(L-1)\Delta f_n}{1+(L-1)^2\Delta f_n^2} & \frac{1+j(L-2)\Delta f_n}{1+(L-2)^2\Delta f_n^2} & \dots & 1 \end{bmatrix} \quad (5.2)$$

onde o cruzamento da n -ésima linha e m -ésima coluna de (5.2) representa a correlação entre os coeficientes de transmissão referentes a n -ésima e m -ésima subportadoras, separadas em frequência por $(m-n)\Delta f$.

Considere um sistema de modulação multiportadora hipotético com: 8 subportadoras, uma componente multipercurso para cada subportadora ($L=8$), $\Delta f=100$ kHz e $B_c=1$ MHz. Nesse caso, a matriz de correlação em (5.2) será

$$\Psi_h = \begin{bmatrix} 1.0000 & 0.9901 & 0.9615 & 0.9174 & 0.8621 & 0.8000 & 0.7353 & 0.6711 \\ 0.9901 & 1.0000 & 0.9901 & 0.9615 & 0.9174 & 0.8621 & 0.8000 & 0.7353 \\ 0.9615 & 0.9901 & 1.0000 & 0.9901 & 0.9615 & 0.9174 & 0.8621 & 0.8000 \\ 0.9174 & 0.9615 & 0.9901 & 1.0000 & 0.9901 & 0.9615 & 0.9174 & 0.8621 \\ 0.8621 & 0.9174 & 0.9615 & 0.9901 & 1.0000 & 0.9901 & 0.9615 & 0.9174 \\ 0.8000 & 0.8621 & 0.9174 & 0.9615 & 0.9901 & 1.0000 & 0.9901 & 0.9615 \\ 0.7353 & 0.8000 & 0.8621 & 0.9174 & 0.9615 & 0.9901 & 1.0000 & 0.9901 \\ 0.6711 & 0.7353 & 0.8000 & 0.8621 & 0.9174 & 0.9615 & 0.9901 & 1.0000 \end{bmatrix} \quad (5.3)$$

$$+j \begin{bmatrix} 0 & -0.0990 & -0.1923 & -0.2752 & -0.3448 & -0.4000 & -0.4412 & -0.4698 \\ 0.0990 & 0 & -0.0990 & -0.1923 & -0.2752 & -0.3448 & -0.4000 & -0.4412 \\ 0.1923 & 0.0990 & 0 & -0.0990 & -0.1923 & -0.2752 & -0.3448 & -0.4000 \\ 0.2752 & 0.1923 & 0.0990 & 0 & -0.0990 & -0.1923 & -0.2752 & -0.3448 \\ 0.3448 & 0.2752 & 0.1923 & 0.0990 & 0 & -0.0990 & -0.1923 & -0.2752 \\ 0.4000 & 0.3448 & 0.2752 & 0.1923 & 0.0990 & 0 & -0.0990 & -0.1923 \\ 0.4412 & 0.4000 & 0.3448 & 0.2752 & 0.1923 & 0.0990 & 0 & -0.0990 \\ 0.4698 & 0.4412 & 0.4000 & 0.3448 & 0.2752 & 0.1923 & 0.0990 & 0 \end{bmatrix}$$

Observe que a correlação diminui conforme aumenta o intervalo em frequência entre as subportadoras.

Utilizando o modelo de canal proposto para gerar as L componentes multipercurso não correlacionadas (com: $f_m = 100$ Hz, $2\sigma_k^2 = 1$, $\forall k$, $T_s = 300$ μ s, 200.000 amostras) e realizando a transformação (3.98) com \mathbf{A} sendo calculada a partir da matriz em (5.3), foi obtida numericamente a matriz \mathbf{C}_T (veja algoritmo “mpath_sim_correl”, Apêndice D). A Figura 5.14 ilustra a amplitude e fase de três das 8 componentes multipercurso obtidas. Observe que, conforme esperado, para diferenças de frequência entre subportadoras de 300 kHz e 400 kHz, as respectivas componentes multipercurso apresentam um grau de correlação maior comparada à correlação apresentada pelas MPC 1 e 8, cujas subportadoras estão separadas por 700 kHz.

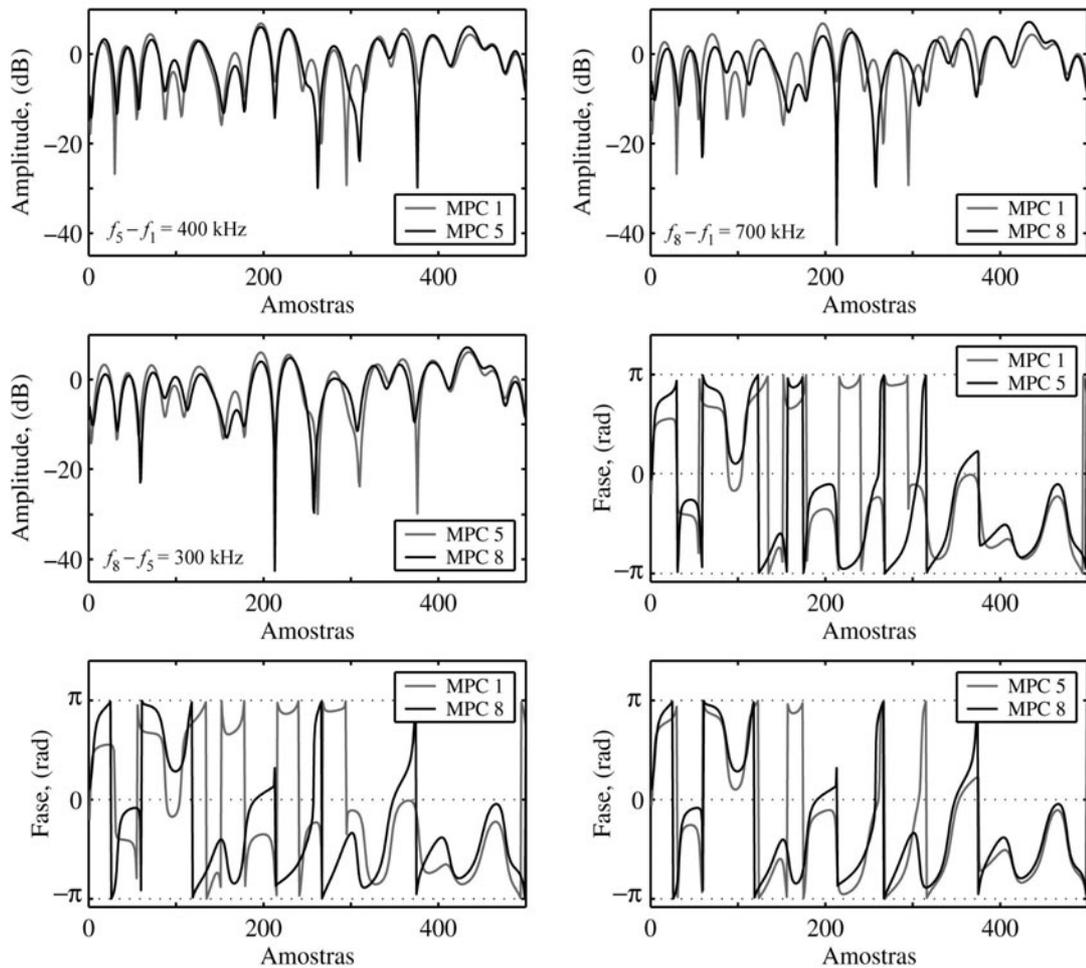


Figura 5.14: Amplitude e fase das MPC’s 1, 5 e 8 obtidas após a transformação.

Seja $\hat{\Psi}_h$ matriz de correlação obtida numericamente e $\epsilon_{\%}$ a matriz de erro percentual com elementos definidos por

$$\varepsilon_{\%}^{m,n} = \left(\left| \frac{\operatorname{Re}\{\Psi_{\mathbf{h}}^{m,n} - \widehat{\Psi}_{\mathbf{h}}^{m,n}\}}{\operatorname{Re}\{\Psi_{\mathbf{h}}^{m,n}\}} \right| + j \left| \frac{\operatorname{Im}\{\Psi_{\mathbf{h}}^{m,n} - \widehat{\Psi}_{\mathbf{h}}^{m,n}\}}{\operatorname{Im}\{\Psi_{\mathbf{h}}^{m,n}\}} \right| \right) \times 100\%, \quad (5.4)$$

então, matriz de erro percentual obtida nesta simulação foi

$$\varepsilon_{\%} = \begin{bmatrix} 0.00 & 0.03 & 0.13 & 0.27 & 0.46 & 0.68 & 0.89 & 1.06 \\ 0.03 & 0.00 & 0.03 & 0.11 & 0.22 & 0.36 & 0.51 & 0.62 \\ 0.13 & 0.03 & 0.00 & 0.02 & 0.08 & 0.16 & 0.25 & 0.32 \\ 0.27 & 0.11 & 0.02 & 0.00 & 0.02 & 0.06 & 0.10 & 0.14 \\ 0.46 & 0.22 & 0.08 & 0.02 & 0.00 & 0.01 & 0.03 & 0.04 \\ 0.68 & 0.36 & 0.16 & 0.06 & 0.01 & 0.00 & 0.01 & 0.01 \\ 0.89 & 0.51 & 0.25 & 0.10 & 0.03 & 0.01 & 0.00 & 0.00 \\ 1.06 & 0.62 & 0.32 & 0.14 & 0.04 & 0.01 & 0.00 & 0.00 \end{bmatrix} + j \begin{bmatrix} 0 & 3.22 & 3.26 & 3.20 & 3.00 & 2.67 & 2.22 & 1.69 \\ 3.22 & 0 & 3.22 & 3.07 & 2.79 & 2.41 & 1.95 & 1.42 \\ 3.26 & 3.22 & 0 & 2.79 & 2.43 & 2.00 & 1.52 & 0.99 \\ 3.20 & 3.07 & 2.79 & 0 & 1.97 & 1.49 & 1.00 & 0.48 \\ 3.00 & 2.79 & 2.43 & 1.97 & 0 & 0.97 & 0.48 & 0.01 \\ 2.67 & 2.41 & 2.00 & 1.49 & 0.97 & 0 & 0.01 & 0.44 \\ 2.22 & 1.95 & 1.52 & 1.00 & 0.48 & 0.01 & 0 & 0.82 \\ 1.69 & 1.42 & 0.99 & 0.48 & 0.01 & 0.44 & 0.82 & 0 \end{bmatrix}$$

Note que houve um erro máximo de 1,06 % na parte real e 3,26% na parte imaginária. A Figura 5.15 ilustra o comportamento desse erro com relação ao número de amostras utilizadas (de 50 mil a 500 mil amostras). Foram realizadas 30 simulações para cada número de amostras, sendo armazenado o valor máximo de erro (parte real e imaginária) apresentado em cada simulação, e ao final realizada uma média sobre esses 30 valores. Verifica-se uma convergência do erro para 1,2% e 0,4% nas partes imaginária e real, respectivamente.

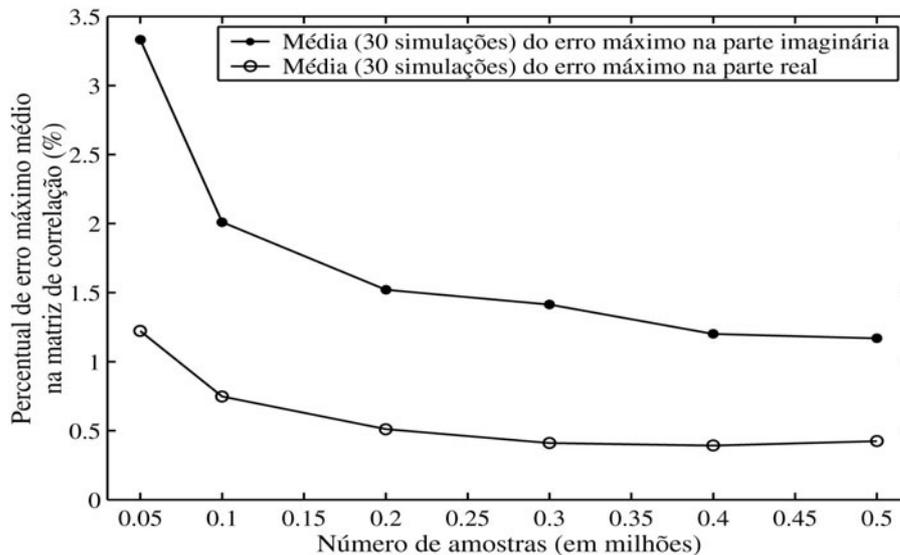


Figura 5.15: Comportamento do erro na matriz de correlação numérica.

Finalmente, cabe ressaltar que esse erro também depende da capacidade do simulador Rayleigh gerar a matriz \mathbf{C} com linhas não correlacionadas.

5.4 SIMULANDO CANAIS COM DESVANECIMENTO RICE

Para simular um canal com desvanecimento Rice utilizando o modelo proposto, uma componente especular deve ser adicionada ao modelo. Assim, de (3.76) tem-se

$$\begin{aligned} \tilde{u}[n] &= T_0(nT_s) + \tilde{c}[n] \\ &= A_0 e^{j(\omega_0 n T_s + \phi_0)} + \frac{1}{N} \sum_{k=0}^{N-1} |S_T[k]| e^{j\phi_k} e^{j2\pi k n / N}, \quad n = 0, 1, \dots, N-1 \end{aligned} \quad (5.5)$$

O modelo acima foi implementado em MATLAB por meio do algoritmo “mpath_sim_rice” (veja Apêndice D). A Figura 5.16 ilustra um exemplo de envoltória obtida do simulador de canal Rice implementado. Observe que, enquanto em canal Rayleigh é comum encontrar desvanecimentos da ordem de 40 dB, neste exemplo os desvanecimentos não passam de 15 dB.

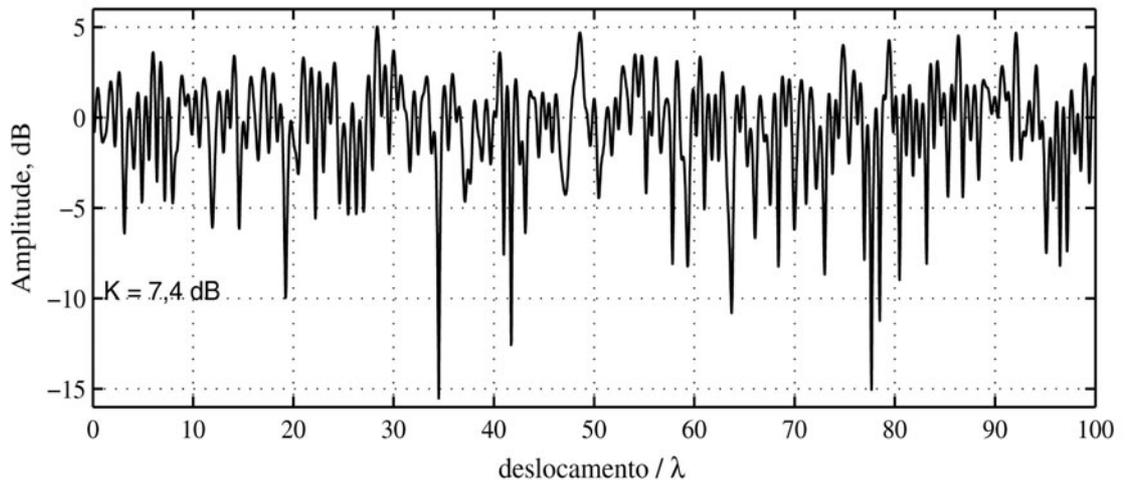


Figura 5.16: Exemplo de envoltória obtida do simulador de canal Rice. $K=7,4$ dB.

Com o objetivo de verificar numericamente as propriedades estatísticas do modelo em (5.5) e compará-las às médias estatísticas para canal com desvanecimento Rice (obtidas no Capítulo 3), foram realizadas diversas simulações, utilizando-se os seguintes parâmetros (veja Capítulo 3, item 3.5):

- $K = 7,4 \text{ dB}$
 - $b_R = 1$
- $$\left. \begin{array}{l} \bullet K = 7,4 \text{ dB} \\ \bullet b_R = 1 \end{array} \right\} \Rightarrow 2\sigma^2 = 0,153955 \text{ e } A_0 = 0,919807;$$
- $f_m = 100 \text{ Hz};$
 - $\omega_0 = 2\pi f_m/2 \Rightarrow \alpha_0 = \pi/3;$
 - $\phi_0 = 0;$
 - $T_s = 250 \mu\text{s};$
 - $N = 50 \times 10^3;$
 - $N_{stat} = 10 \times 10^3.$

Observe que com os valores atribuídos a ω_0 e α_0 o modelo deixa de ser WSS e conseqüentemente também deixa de ser ergódico. Desta forma as simulações devem ser realizadas considerando inúmeras funções amostras. O parâmetro N_{stat} (número de amostras estatísticas) acima indica o número de funções amostras utilizadas na simulação. O valor do fator Rice foi retirado da Tabela 3.2, que se refere a um canal Rice em ambiente urbano com freqüência de propagação igual a 1,88 GHz. Um móvel a 57,45 km/h produziria um máximo deslocamento Doppler igual ao valor escolhido para f_m . Já o valor o ângulo de incidência α_0 foi escolhido arbitrariamente, já que o mesmo pode assumir qualquer valor entre $-\pi$ e π .

A Figura 5.17 ilustra a função complexa de autocorrelação obtida numericamente. A curva de referência pode ser encontrada em (3.47). Pode ser observado que as curvas se sobrepõem durante todo o intervalo de tempo considerado.

Como o valor médio do processo é variante no tempo, as pdf's da partes real e imaginária, $f_x(x,\tau)$ e $f_y(y,\tau)$ respectivamente, são também variantes no tempo. A Figura 5.18 ilustra estas funções densidade de probabilidade obtidas numericamente. As curvas de referência são pdf's Gaussianas com valor médio igual a $m_R(\tau)$ e $m_I(\tau)$ e variância comum igual a σ^2 . Cabe observar que a densidade de probabilidade é contínua no tempo, apesar do gráfico ilustrar a mesma apenas para valores discretos no tempo (a cada 2 milissegundos). Note que há uma boa concordância entre os resultados teóricos e simulados.

Finalmente, a Figura 5.19 e a Figura 5.20 ilustram as densidades de probabilidade para fase e módulo, respectivamente, em canal Rice, obtidas por meio de simulação. A pdf teórica de fase (referência no gráfico) pode ser encontrada em (3.45). Observe-se que em ambos os casos as curvas teórica e simulada estão muito próximas. Nota-se ainda que a pdf de fase é variante no tempo e a de módulo não, conforme esperado.

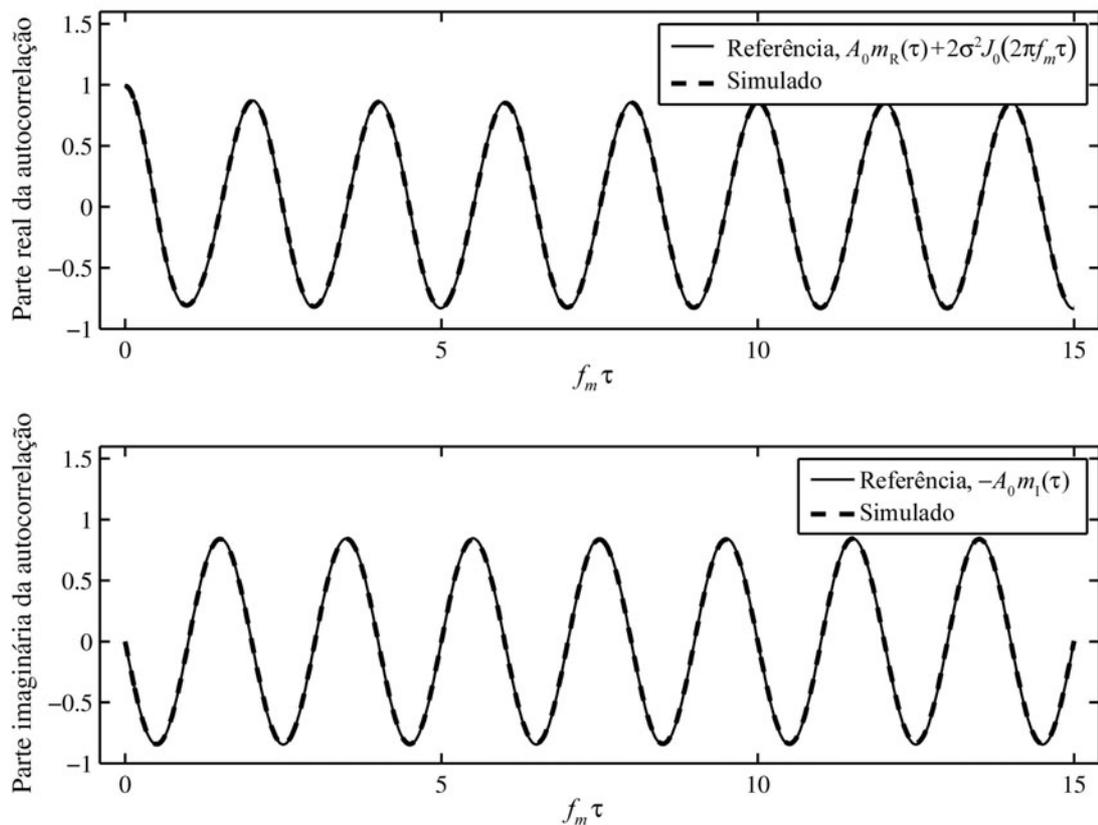


Figura 5.17: Função de autocorrelação do modelo de canal Rice obtida em simulação.

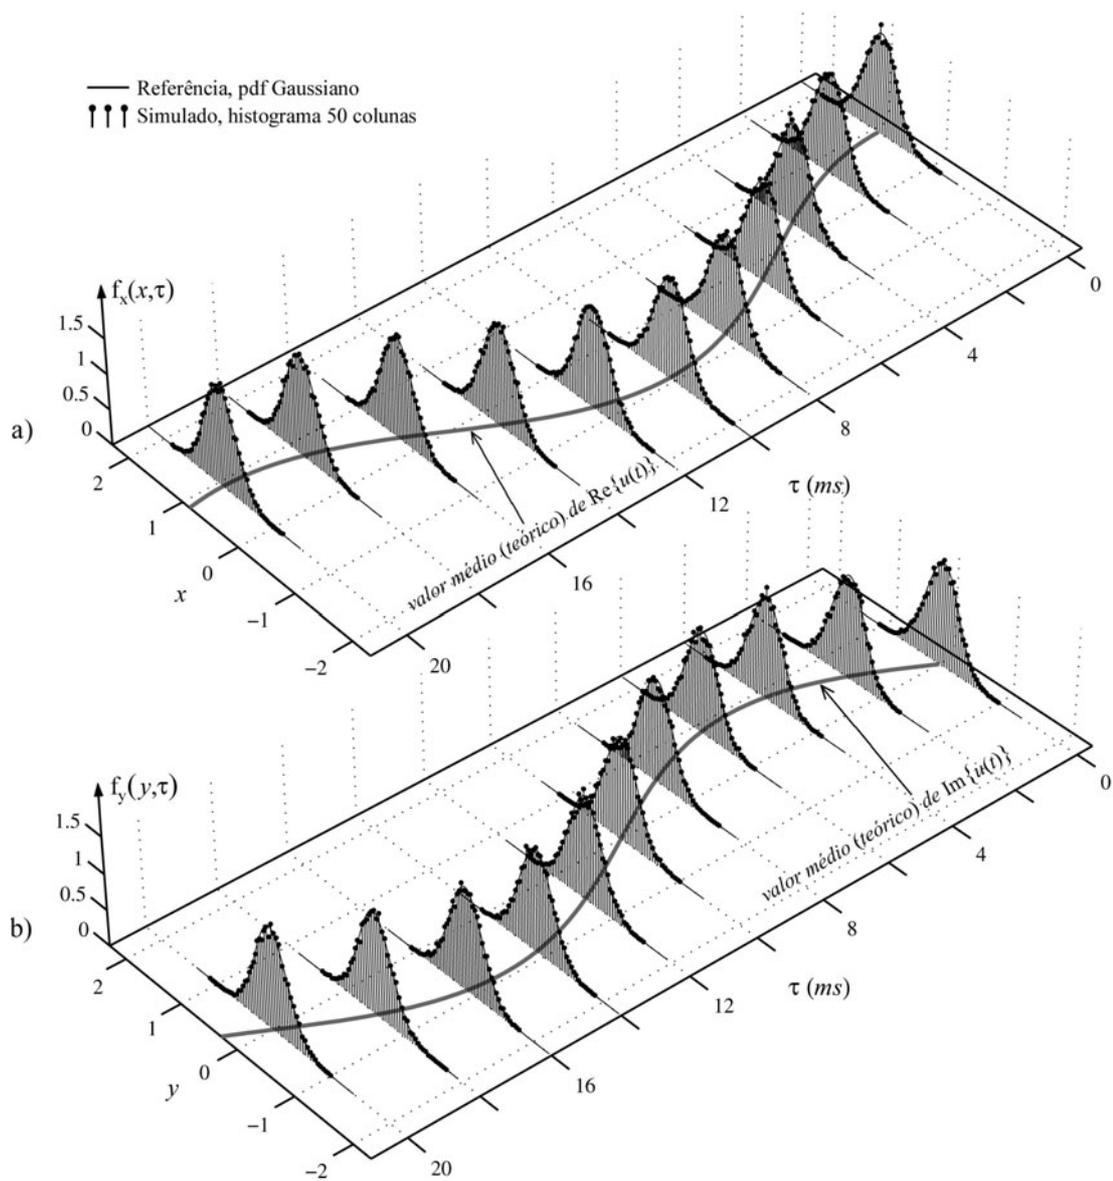


Figura 5.18: Curvas de densidade de probabilidade e histogramas das partes: a) real e b) imaginária do simulador de canal Rice.

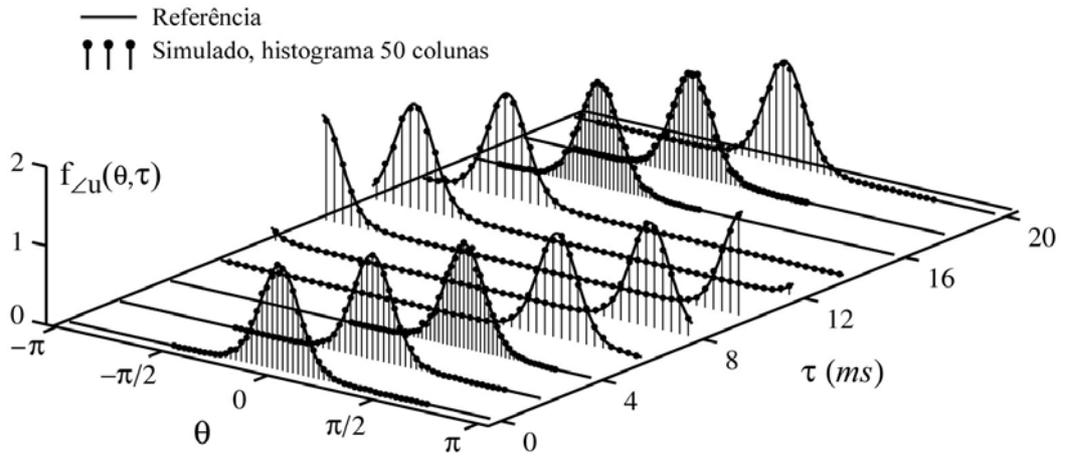


Figura 5.19: Densidade de probabilidade de fase em canal Rice obtida por simulação.

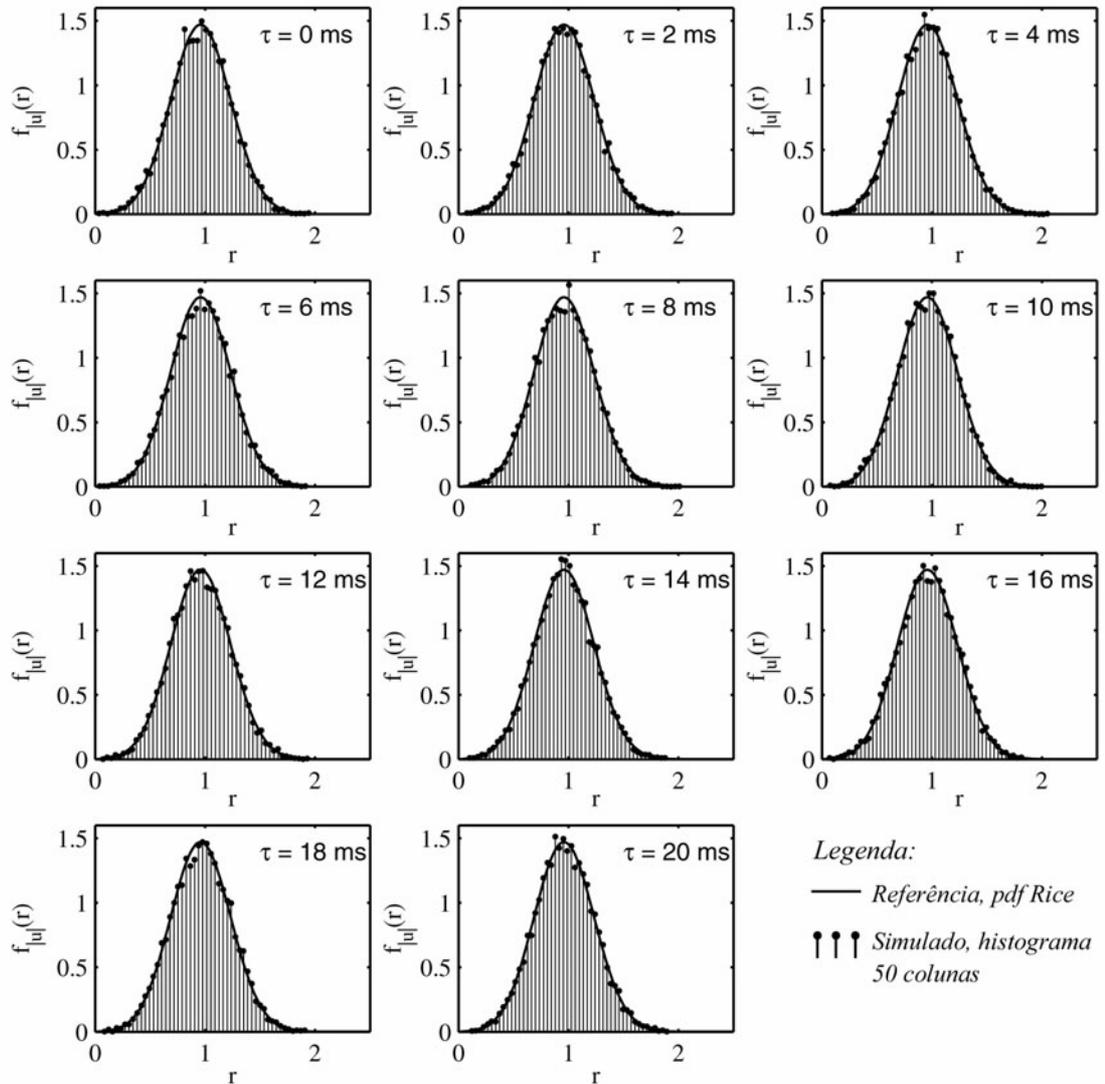
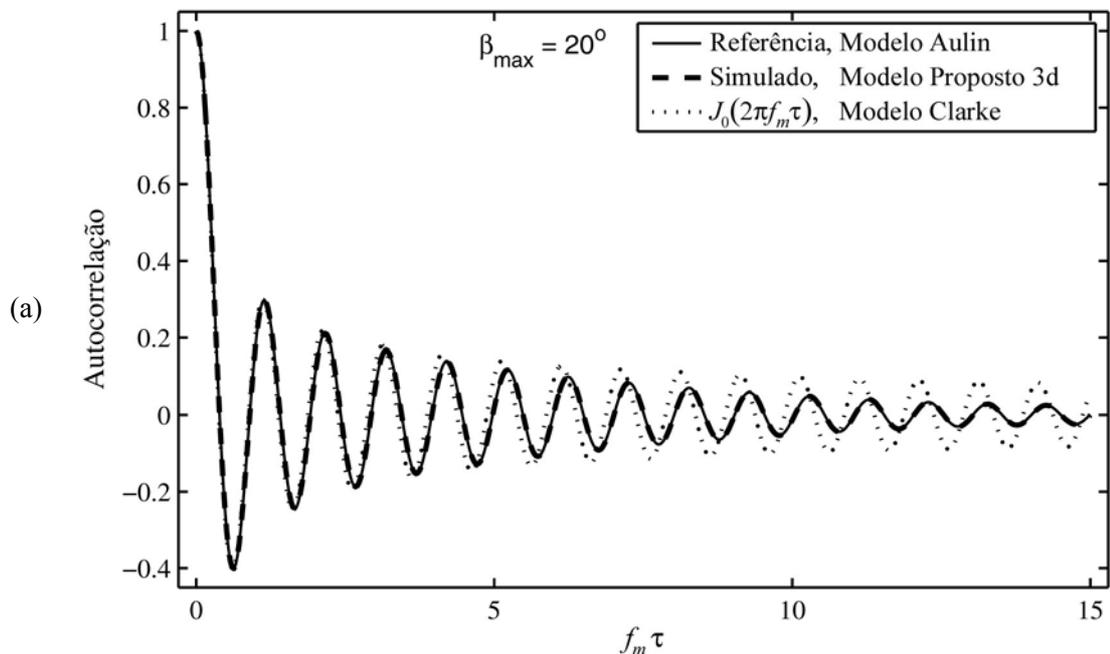


Figura 5.20: Densidade de probabilidade de módulo em canal Rice obtida por simulação.

5.5 RESULTADOS DE SIMULAÇÃO DO MODELO PROPOSTO 3D

Com exceção da função de autocorrelação, as propriedades estatísticas desse modelo são iguais às propriedades do modelo proposto baseado no modelo bidimensional de Clarke, as quais já foram devidamente simuladas. Desta forma, neste item somente a função de autocorrelação será obtida numericamente.

Para implementar o modelo proposto 3d, definido em (4.33), criou-se o algoritmo “mpath_sim_3d_v01” (veja Apêndice D). A Figura 5.21 ilustra os resultados numéricos obtidos para função de autocorrelação, tendo como referência a função de autocorrelação do modelo teórico de Aulin. A figura também ilustra a função de autocorrelação do modelo de Clarke apenas para comparação. Note que há um perfeito ajuste entre a curva de referência e as curvas obtidas por simulação, indicando a eficácia do modelo proposto adaptado para simular um ambiente com propagação não horizontal.



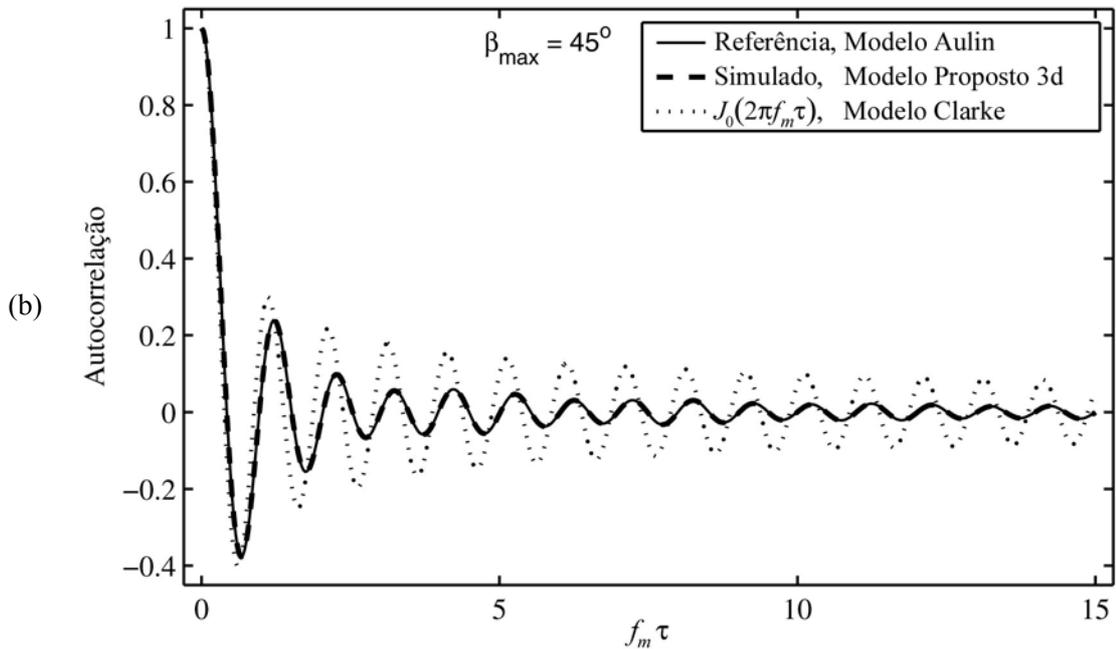


Figura 5.21: Função de autocorrelação obtida por simulação do modelo proposto 3d;

$f_m = 100\text{Hz}$, $T_s = 300\mu\text{s}$, $2\sigma^2 = 1$, $N = 50$ mil, (a) $\beta_{\max} = 20^\circ$ e (b) $\beta_{\max} = 45^\circ$.

5.6 COMPARAÇÕES ENTRE MODELOS

Descreve-se nesta seção alguns resultados de simulação entre o modelo proposto e os modelos de Smith modificado por Young [15] e de Jakes modificado por Zheng [16], aqui denominados simplesmente de Smith modificado e Jakes modificado. As rotinas utilizadas nas simulações são “mpath_sim_zheng2003” e “mpath_sim_young” (veja APÊNDICE D), respectivamente.

O objetivo das simulações é avaliar as médias temporais em cada modelo, tomando como referência as médias estatísticas em (3.14), assim como avaliar o tempo de execução em cada modelo. Os parâmetros utilizados para os três modelos nas simulações são: $2\sigma^2 = 1$, $f_m T_s = 0,025$ e $N = 50 \times 10^3$. No modelo de Jakes modificado foram utilizados 8 osciladores ($M = 8$), conforme sugerido pelo autor [16].

5.6.1 DENSIDADES DE PROBABILIDADE

As densidades de probabilidade numéricas foram obtidas através de um histograma

de 30 colunas. A Figura 5.22 ilustra o resultado obtido para densidade de probabilidade de módulo. A curva de referência é a pdf Rayleigh com $2\sigma^2 = 1$. Note que a curva simulada no modelo Jakes modificado apresenta um desvio da curva de referência. Já os modelos de Smith modificado e proposto apresentam resultados semelhantes e satisfatórios. Acima de cada curva está impresso a variância (temporal) das funções amostras dos respectivos modelos. No modelo Jakes modificado as variâncias da parte real e imaginária apresentam valores diferentes entre si (enquanto deveriam ser iguais), além de estarem distantes do valor desejado 0,5. Já nos modelos Smith modificado e proposto os valores estão conforme o esperado.

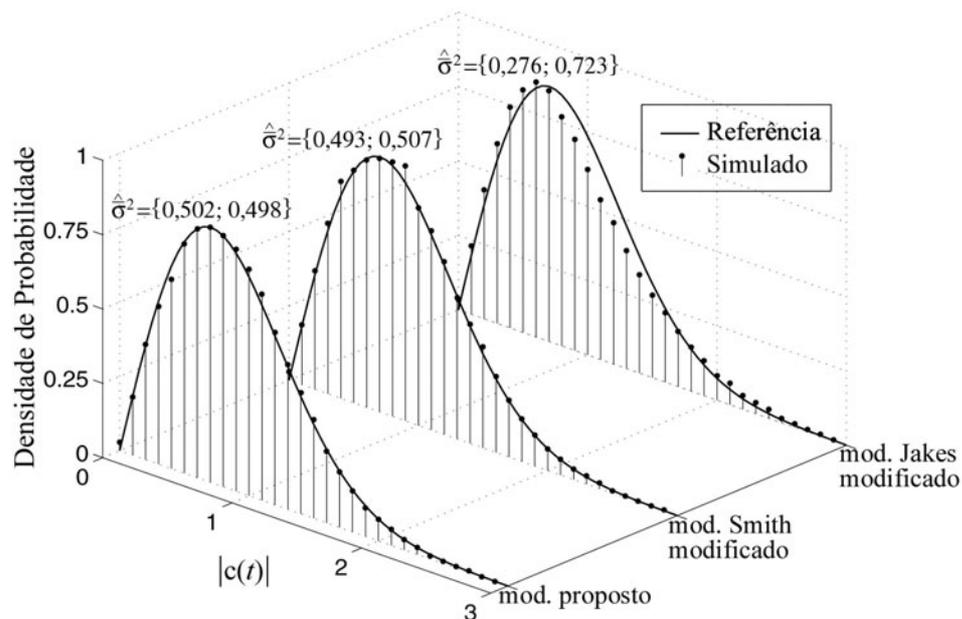


Figura 5.22: Densidade de probabilidade de módulo para os três modelos analisados.

Referência: pdf Rayleigh com $2\sigma^2 = 1$. Notação: $\hat{\sigma}^2 = \{\text{var}(c_R(t)); \text{var}(c_I(t))\}$.

A Figura 5.23 ilustra os resultados obtidos nas simulações de densidade de probabilidade de fase. A curva de referência é a pdf uniforme e igual a $1/(2\pi)$. Novamente os resultados apresentados pelos modelos Smith modificado e proposto são semelhantes e estão próximos da curva de referência. Já no modelo Jakes modificado a figura mostra um elevado desvio da curva de referência o que caracteriza a não uniformidade da densidade de probabilidade nesse modelo.

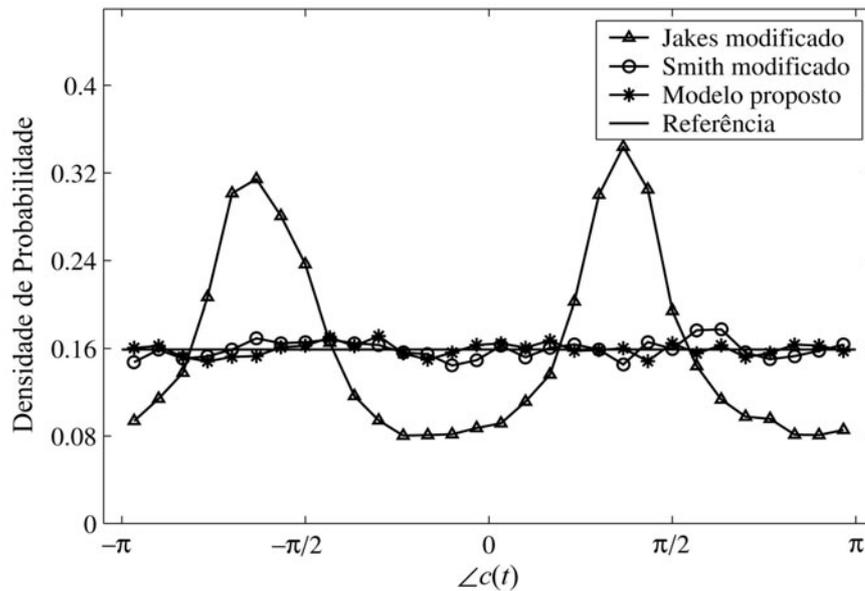


Figura 5.23: Densidade de probabilidade de fase para os três modelos analisados.

Referência = $1/(2\pi)$.

5.6.2 FUNÇÕES DE CORRELAÇÃO

A Figura 5.24 ilustra os resultados numéricos obtidos para correlação cruzada entre as partes real e imaginária das funções amostras geradas em cada modelo. A referência é a curva $\bar{h}(\tau) = 0$ (correlação temporal nula). O valor máximo que cada curva $\bar{h}(\tau)$ obtida de forma numérica pode assumir (pior caso) é igual 0,5. Assim, $\bar{h}(\tau)/\sigma^2$ pode assumir valor máximo igual 1. A figura ilustra um elevado grau de correlação (maior que 40%) no modelo Jakes modificado, que permanece mesmo para um deslocamento temporal elevado entre as funções amostras. O modelo proposto apresenta resultados limitados a uma faixa de $\pm 0,05$ e o modelo Smith modificado à uma faixa de $\pm 0,09$. Apesar do modelo proposto apresentar resultado mais próximo do zero que o de Smith modificado, em ambas as partes real e imaginária das funções amostras podem ser consideradas não correlacionadas.

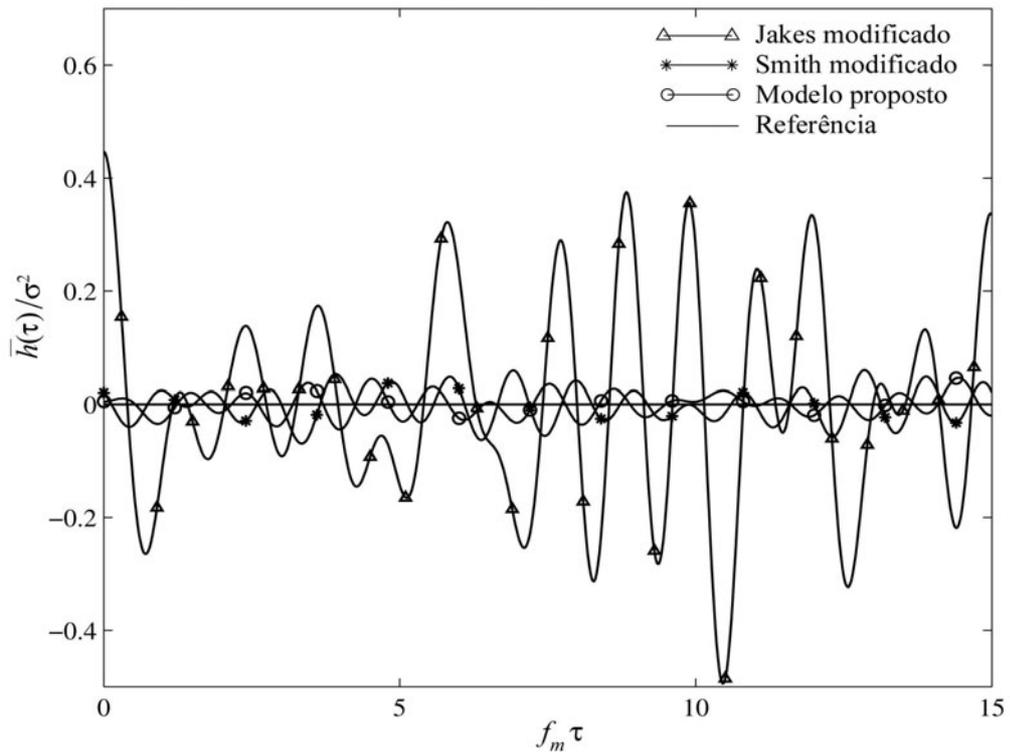


Figura 5.24: Correlação cruzada entre as partes real e imaginária de uma função amostra gerada por cada modelo. Referência: $\bar{h}(\tau) = 0$.

As Figuras 5.25, 5.26 e 5.27 ilustram os resultados obtidos na autocorrelação das funções amostras geradas em cada modelo e autocorrelação de suas partes real e imaginária. Verifica-se que nos três casos, o modelo Jakes modificado apresenta uma grande divergência das curvas de referência (lembrando que no Capítulo 3 foi verificado que nesse modelo estas curvas dependem altamente do número de osciladores utilizados). Nas simulações deste capítulo foram utilizados somente 8 osciladores, conforme sugerido em [16], onde afirma-se que esse número é suficiente para que bons resultados em médias estatísticas sejam obtidos. Nota-se porém, que para médias temporais essa quantidade de osciladores não é suficiente.

No modelo proposto, a curva de autocorrelação $\bar{R}_c(\tau)$ casa perfeitamente com a curva de Bessel (conforme já apresentado no início deste Capítulo), enquanto no modelo Smith modificado há um leve desvio da curva. Nos outros dois gráficos (Figuras 5.26 e 5.27) o resultado permanece, com um leve desvio também por parte do modelo proposto na parte final da curva.

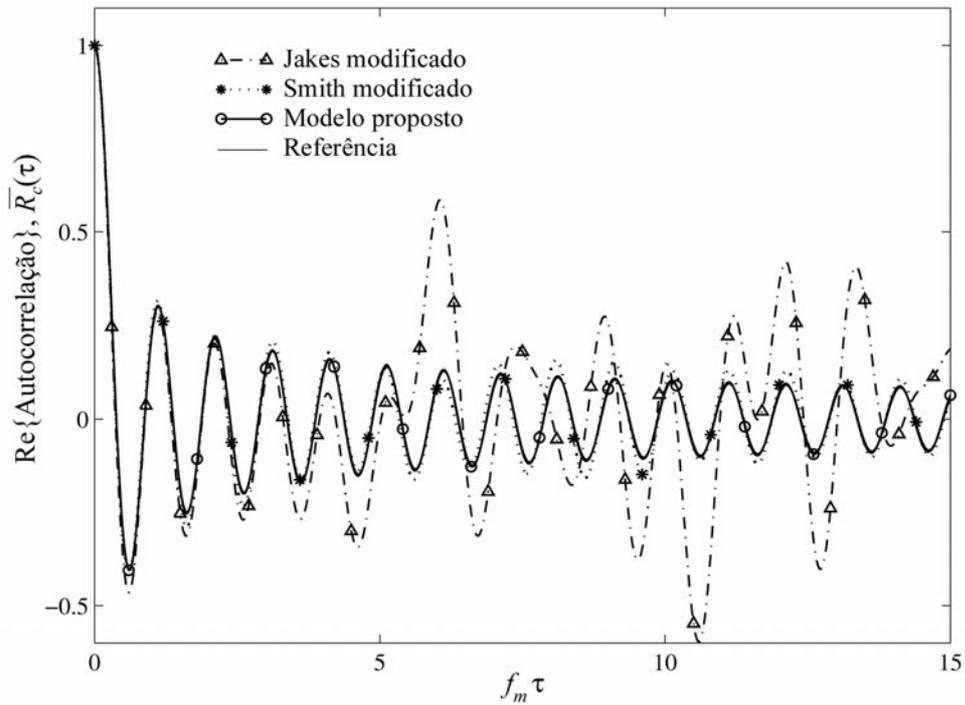


Figura 5.25: Parte real da autocorrelação das funções amostras geradas em cada modelo.

Referência: $R_c(\tau) = 2\sigma^2 J_0(2\pi f_m \tau)$.

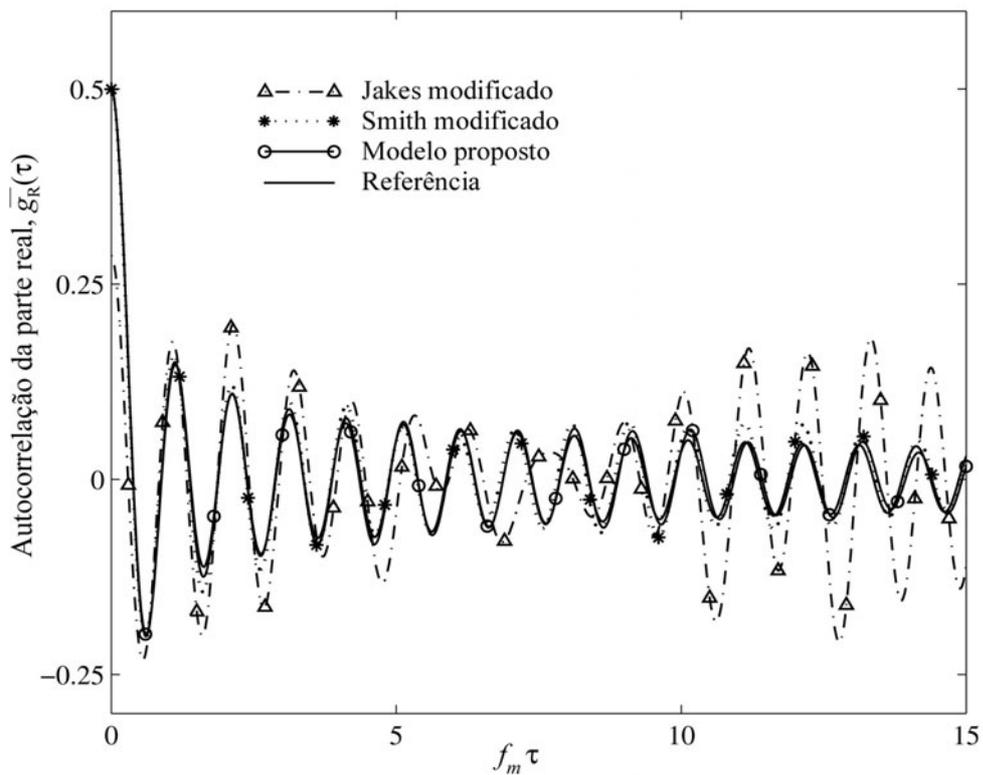


Figura 5.26: Autocorrelação da parte real das funções amostras geradas em cada modelo.

Referência: $g(\tau) = \sigma^2 J_0(2\pi f_m \tau)$.

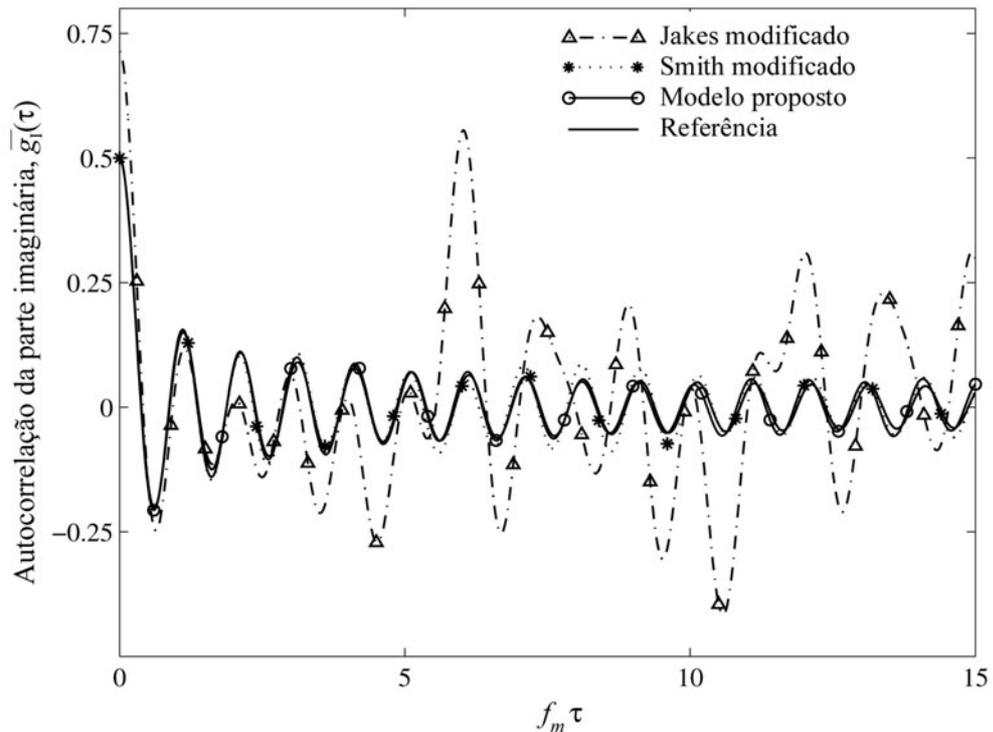


Figura 5.27: Autocorrelação da parte imaginária das funções amostras geradas em cada modelo. Referência: $g(\tau) = \sigma^2 J_0(2\pi f_m \tau)$.

5.6.3 COVARIÂNCIA ENTRE FUNÇÕES AMOSTRAS

As Figuras 5.28 e 5.29 ilustram os resultados de simulação obtidos para covariância entre duas funções amostras geradas em cada modelo. A curva de referência é a de covariância igual a zero. As curvas obtidas estão limitadas às seguintes faixas:

- Jakes modificado: parte real $\pm 0,007$ e parte imaginária $\pm 0,008$;
- Smith modificado: parte real $\pm 0,06$ e parte imaginária $\pm 0,09$;
- Modelo proposto: parte real $\pm 0,08$ e parte imaginária $\pm 0,07$.

Verifica-se que o modelo Jakes modificado apresenta o resultado mais próximo de zero. Já os modelos proposto e Smith modificado apresentam resultados semelhantes e também próximos de zero. Nesse caso, os valores obtidos são pequenos o suficiente para que as funções amostras possam ser consideradas não correlacionadas nos três modelos.

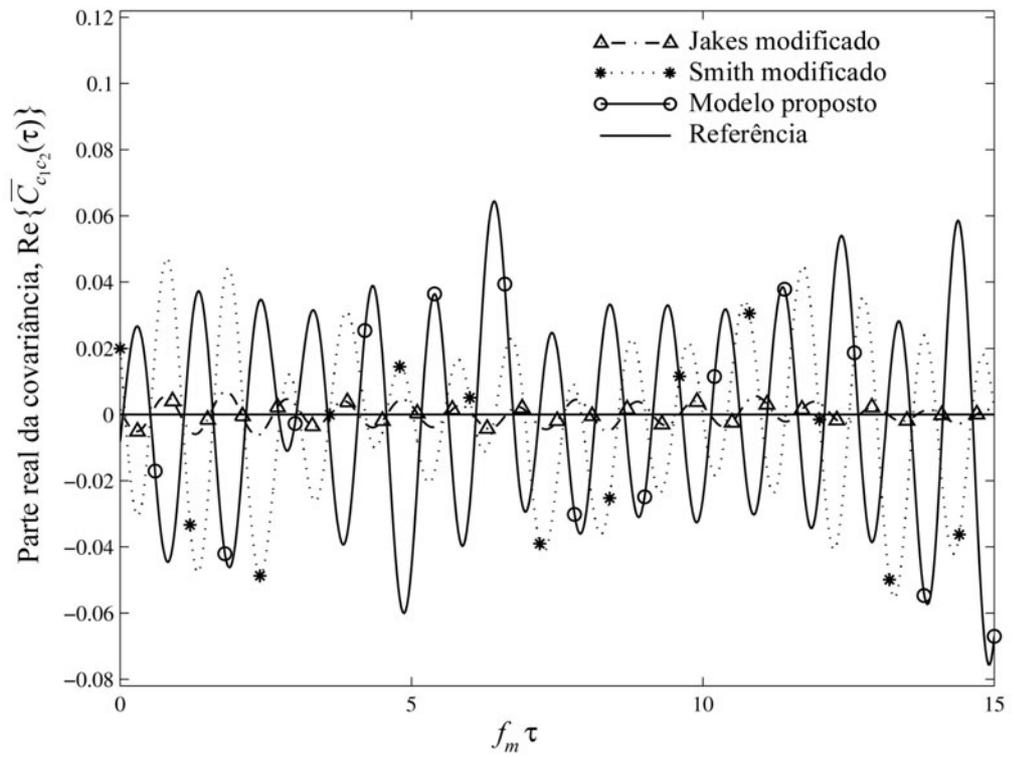


Figura 5.28: Parte real da covariância entre duas funções amostras obtidas em cada modelo.

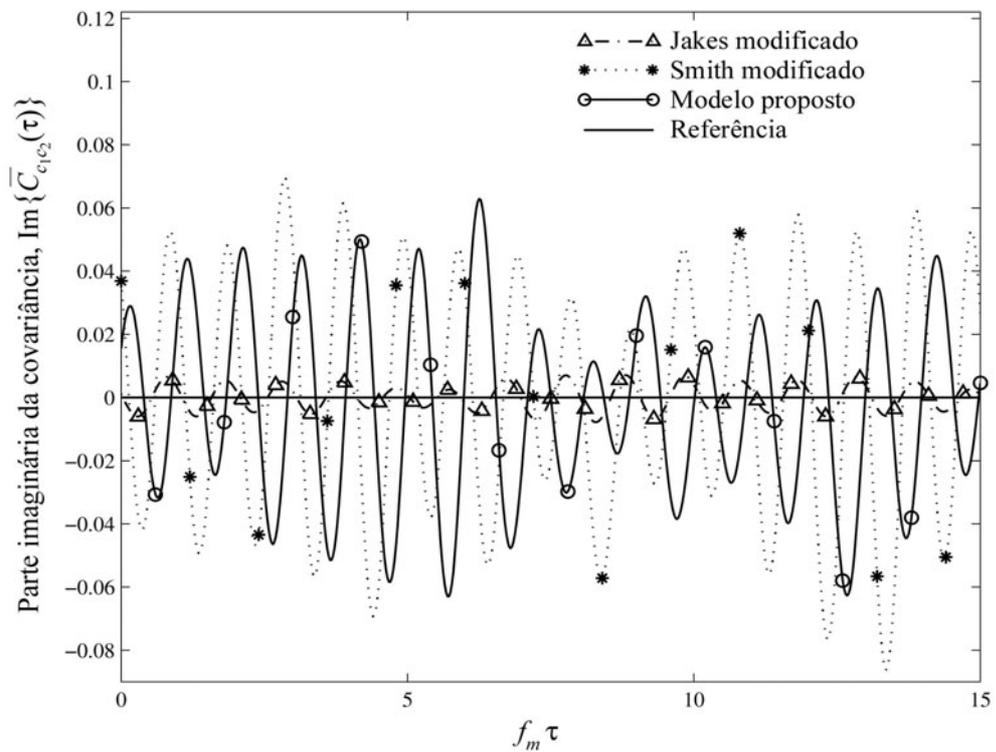


Figura 5.29: Parte imaginária da covariância entre duas funções amostras obtidas em cada modelo.

5.6.4 TEMPO DE EXECUÇÃO

Uma comparação entre o tempo de execução médio normalizado dos três modelos está ilustrada na Figura 5.30. Para os dois modelos que utilizam a IFFT a figura ilustra uma curva de ET_{avp2} e uma curva de ET_{av} considerando valores de N múltiplos de 10^4 . Esta última também se aplica ao modelo de Jakes modificado. Verifica-se que o modelo proposto e o de Smith modificado apresentaram resultados muito semelhantes e em ambos a curva de ET_{av} acompanha de perto a curva de ET_{avp2} . Para o modelo proposto esse resultado já era conhecido, o qual foi ilustrado no item 5.1. Conforme ilustra a Figura 5.4.b, o ET_{av} apresentado por ambos os modelos IDFT pode ainda ser melhorado com o uso do quantizador da Figura 5.3. Já o modelo de Jakes modificado se mostrou várias vezes mais lento que os outros dois, mesmo para um número pequeno de osciladores ($M=8$). Ressalta-se que nos modelos baseados em soma de osciladores, o tempo de execução é diretamente proporcional ao número de osciladores.

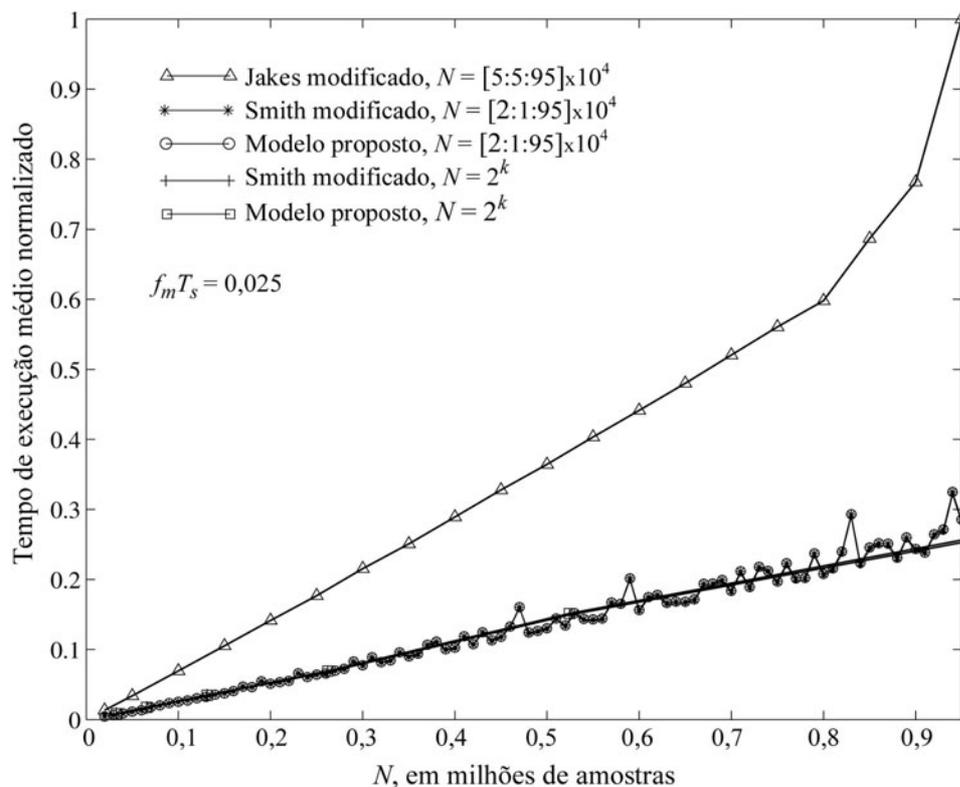


Figura 5.30: ET_{av} e ET_{avp2} . Média realizada sobre 30 simulações com um conjunto de 6 funções amostras em cada uma. Notação: $N = [\text{início} : \text{incremento} : \text{fim}]$.

CAPÍTULO 6

DISCUSSÃO DOS RESULTADOS

No Capítulo 2 foram apresentadas informações detalhadas sobre a implementação dos principais modelos de predição de perda percurso para macro e microcélulas. Não houve neste trabalho a preocupação de ilustrar por meio de algoritmos (em linguagem de programação) a implementação de tais modelos, uma vez que esta se dá de forma direta a partir das equações apresentadas para cada modelo.

Os canais com desvanecimento Rayleigh e Rice foram apresentados em detalhe no Capítulo 3 quanto às suas características de propagação, comportamento estatístico, densidade espectral de potência e formas de modelagem matemática e computacional.

A seção inicial desse capítulo contribuiu para um melhor entendimento das causas do processo de desvanecimento ocorrido no canal, assim como das diversas variáveis envolvidas nesse processo, fornecendo o conhecimento necessário para a análise dos modelos computacionais apresentados em seguida. Entre as variáveis em questão, encontra-se o ângulo de elevação (no modelo tridimensional), que com frequência não é considerada em simulações de canal com desvanecimento. A decisão de considerar ou não esta variável nas simulações irá depender do tipo de aplicação em questão, podendo ser justificada pelas informações contidas nesta seção.

Tem sido verificado em diversos trabalhos onde é necessário simular um canal com desvanecimento Rice, que a simplificação (3.49) é adotada, pois torna o modelo de canal estacionário no sentido amplo. As situações de transmissão onde esta hipótese é verdadeira são muito específicas, que certamente ocorrem na minoria do tempo de duração de uma transmissão. Por outro lado, pode haver uma redução na complexidade dos cálculos quando o processo é WSS. Especificamente, somente a fase do canal Rice é não WSS. Assim, em simulação de sistemas com detecção não coerente ou detecção coerente com estimativa perfeita de fase, a hipótese em questão

é perfeitamente válida. Há que se verificar porém, o efeito da não estacionariedade da fase sobre a resposta do estimador de fase, para confirmar se a estimativa perfeita de fase é uma boa hipótese.

O modelo de Dent tem sido amplamente utilizado no meio científico em simulações que exijam a modelagem de canal com desvanecimento Rayleigh. Tem como características principais a ergodicidade, a estacionariedade (no sentido amplo) e a correlação extremamente baixa entre funções amostras sem deslocamento temporal. Por outro lado, apresenta elevada correlação entre as partes real e imaginária. Tem como fator limitante o número máximo de funções amostras, que é igual ao número de osciladores utilizados. Considere por exemplo a simulação de um sistema de comunicação móvel DS-CDMA (*Direct Sequence Code Division Multiple Access*) em ambiente multipercurso, com múltiplos usuários dentro de uma mesma célula. Considere ainda que o sistema contém 10 usuários ativos, que somente 8 componentes multipercurso por usuário serão consideradas e que o simulador (3.64) será implementado com 16 osciladores. Desta forma, cada realização do conjunto $\{\phi_n\}$ pode gerar 16 componentes multipercurso que podem ser atribuídas a dois usuários. Serão portanto necessárias 5 realizações de $\{\phi_n\}$ para “atender” aos 10 usuários. A partir desse exemplo e das propriedades do modelo apresentadas neste trabalho, pode-se tirar as seguintes informações:

- a) As componentes multipercurso de um mesmo usuário serão não correlacionadas;
- b) As componentes multipercurso de dois usuários diferentes, porém oriundas da mesma realização $\{\phi_n\}$ também serão não correlacionadas;
- c) Pode haver uma correlação elevada entre componentes multipercurso de usuários distintos, caso não sejam provenientes da mesma realização $\{\phi_n\}$.

Veja na Figura 3.20 que a informação c) acima é bastante provável e que certamente trará resultados indesejáveis na simulação, pois fisicamente não há correlação entre componentes de usuários diferentes a menos que estes estejam localizados em posições muito próximas (dentro da mesma sala por exemplo). Para evitar esta situação uma solução possível seria aumentar para 128 (número em potência de 2 imediatamente acima de 80) o número de osciladores utilizados no modelo. O

“preço” de tal solução é o aumento do esforço computacional (na geração de cada componente multipercurso) em aproximadamente 8 vezes. Finalmente, cabe ressaltar que os números utilizados neste exemplo são muito comuns em simulações de sistemas DS-CDMA.

O modelo apresentado por Zheng não apresenta limitação quanto ao número de componentes multipercurso. Tem como característica principal todas as médias estatísticas corretas, o que representa uma vantagem sobre o modelo de Dent. Apresenta ainda uma correlação entre componentes multipercurso muito baixa para qualquer deslocamento temporal. Por outro lado, a ergodicidade prática do modelo depende fortemente do número de osciladores utilizados. Neste trabalho foi verificado que devido a esse fato, um número de osciladores razoável deve estar acima de 64. Mais uma vez, deve-se ressaltar que essa quantidade de osciladores exigirá um elevado esforço computacional.

O modelo de Smith tem como características principais o fato de possuir médias estatísticas corretas (implica ser WSS), de ser ergódico e ter a capacidade de gerar componentes não correlacionadas. A quantidade de geradores de números aleatórios caiu de 4 para 2 após a modificação proposta por Young. Além disso, tornou-se necessário calcular apenas uma IDFT, resultando em uma queda no esforço computacional, que aliado ao uso da IFFT tornou esse modelo computacionalmente eficiente enquanto permanece matematicamente correto.

Ainda no Capítulo 3, realizou-se uma descrição do modelo COST259. Esse simulador contempla senão todas, a grande maioria dos efeitos que um sinal pode sofrer em um canal de comunicação móvel. Seus vários parâmetros de entrada e saída possibilitam a escolha de qual ou quais efeitos simular, podendo ser útil para diferentes áreas de estudo. É nesse contexto que se encontra a utilidade de tal descrição, que visa uma maior familiaridade para com o modelo, seu manuseio e suas propriedades estatísticas. Informações úteis do ponto de vista de simulação foram apresentadas, algumas ilustrando conceitos novos sobre simuladores de canal. Componentes agrupadas em *clusters*, ambientes com mais de 40 (chegando facilmente a 120) componentes multipercurso e frequência Doppler variável são características próprias do modelo. Alguns dos processos aleatórios utilizados na

composição do modelo tiveram seus parâmetros caracterizados por medidas de campo, o que contribui para uma maior aproximação entre modelo e canal real.

Finalmente, cabe ressaltar que para algumas aplicações, como simulação Monte Carlo em análise de desempenho de sistemas de comunicação móvel, o COST259 poderá exigir um elevado esforço computacional, tempo de processamento e capacidade de armazenamento na simulação. O número de componentes multipercurso geradas pelo COST259 quando multiplicado pelo número de usuários presentes no sistema e pelo número de pontos necessários para a simulação podem tornar a simulação proibitiva para os microcomputadores pessoais disponíveis atualmente. Esta característica do modelo juntamente com o fato de que o mesmo não é de domínio público pode justificar o uso dos demais modelos de canais apresentados neste trabalho.

No Capítulo 4, foi apresentado um novo método para geração de coeficientes de transmissão em canal com desvanecimento multipercurso. Quando implementado em *software*, o método dá origem a um simulador matematicamente eficaz e computacionalmente eficiente. Suas médias estatísticas e temporais calculadas são as mesmas encontradas no modelo de Clarke, o que indica que o modelo tem propriedades estatísticas corretas, além de ser ergódico em média, autocorrelação e correlação cruzada entre suas componentes real e imaginária.

A adaptação do modelo proposto ao modelo teórico tridimensional de Aulin é de certa forma facilitada, pois para tal basta conhecer a função densidade de probabilidade do ângulo de elevação, sem que se tenha a preocupação em gerar esta variável aleatória. Mesmo que o cálculo da transformada de Fourier em (3.30) seja de elevada complexidade, esse procedimento pode ser realizado numericamente.

Para a mesma adaptação (3D) nos modelos baseados em soma de senóides (Jakes, Dent, Zheng, por exemplo) faz-se necessário disponibilizar um gerador de números aleatórios para o ângulo de elevação. Assim, dada a função densidade de probabilidade do ângulo de elevação, deve-se encontrar um método para criar esta variável aleatória, caso tal método não seja conhecido.

Os resultados de simulação do Capítulo 5 reproduzem os resultados analíticos do

modelo proposto e confirmam a sua validade, fato importante por se tratar de um modelo novo. Além disso, resultados numéricos comparativos são apresentados, evidenciando as qualidades e limitações dos principais simuladores de canal com desvanecimento.

Com o auxílio de um quantizador utilizado para transformar o número inicial de amostras, o tempo de execução apresentado pelo modelo proposto se sobrepõe à curva de tempo de execução para número de amostras em potência de dois. Esse é um excelente resultado, uma vez que tempo de execução e esforço computacional podem ser considerados diretamente proporcionais. Na análise comparativa de tempo de execução ilustrada na Figura 5.30 esta qualidade do modelo fica mais evidente. Note que mesmo quando somente 8 osciladores são utilizados no modelo de Jakes modificado, o modelo proposto pode ser aproximadamente 3 vezes mais rápido nas simulações.

Nas simulações realizadas com o intuito de obter as propriedades estatísticas de forma numérica como: função densidade de probabilidade, taxa de ocorrência de nulos, taxa de cruzamento de nível, duração média dos desvanecimentos, correlação entre componentes multipercurso, funções de autocorrelação e correlação cruzada, os resultados mostraram concordância com os resultados teóricos em todos os casos. Assim, as simulações confirmaram as propriedades estatísticas corretas do modelo proposto obtidas analiticamente.

Devido a capacidade de gerar componentes multipercurso não correlacionadas apresentada pelo modelo, é possível aplicar uma transformação nas componentes, de forma que sejam geradas componentes correlacionadas que apresentem uma matriz de correlação especificada previamente. Nas simulações realizadas para verificar o comportamento do modelo nesta situação, o resultado foi um erro máximo médio baixo quanto à matriz de correlação, mesmo para um número pequeno de amostras e convergindo para um valor ainda menor (veja Figura 5.15). Esses resultados podem ser considerados satisfatórios.

Os resultados de simulação para canal com desvanecimento Rice a partir do modelo proposto também se mostraram satisfatórios em todos os testes realizados, indicando

que o modelo também é adequado para simular esse tipo de canal. O mesmo aconteceu nas simulações do modelo proposto 3D, com sobreposição das curvas teóricas e simuladas.

Ficou ilustrado neste trabalho que o modelo proposto e o de Smith modificado apresentam métodos de geração de coeficientes diferentes. Mais especificamente, uma variável aleatória Rayleigh está presente na geração do modelo de Smith modificado e ausente no modelo proposto. Isto faz com que o modelo proposto tenha um gerador de número aleatório a menos. Além disso, ambos diferem levemente na forma como o filtro em frequência foi projetado. Apesar das diferenças entre os métodos, os modelos IDFT apresentaram resultados semelhantes em todas as simulações comparativas realizadas, onde os resultados podem ser considerados satisfatórios. Ficou constatado que mesmo com um gerador de números aleatórios a menos, o modelo proposto apresentou curva de tempo de execução casando com a curva apresentada pelo modelo de Smith modificado. Em outras palavras, não houve diferença significativa (utilizando os microcomputadores pessoais atuais) que justificasse a escolha de um ou outro modelo pelo critério de tempo de execução. Porém, isto pode resultar em economia de espaço em memória numa possível implementação em *hardware*.

Há um ajuste levemente melhor da curva de função de autocorrelação apresentada pelo modelo proposto comparado ao ajuste apresentado pelo modelo de Smith modificado. Isto pode ser explicado pelo fato de que a densidade espectral de potência apresentada pelo modelo proposto é exatamente a expressão de DEP obtida por Clarke, a qual forma um par de transformada de Fourier com a função de Bessel modificada de primeira classe e ordem zero. Já o modelo de Smith modificado apresenta uma densidade espectral de potência que é a DEP obtida por Clarke multiplicada por uma variável aleatória com distribuição chi-quadrado (RV Rayleigh elevada ao quadrado), devido à presença da RV Rayleigh multiplicando o filtro na geração dos coeficientes de transmissão. Assim, a transformada de Fourier da DEP de Clarke multiplicada por uma RV chi-quadrado não resulta diretamente na função de Bessel. Mas, à medida que se aumenta o número de amostras, há uma convergência da curva de função de autocorrelação obtida para a curva de Bessel.

Com exceção da covariância entres funções amostras, o modelo de Jakes modificado apresentou em todas as simulações comparativas resultados divergentes das curvas de referência, confirmando os cálculos de médias temporais realizados no Capítulo 3. Isto veio confirmar que apesar do modelo apresentar médias estatísticas corretas, o mesmo não pode ser considerado ergódico quando o número de osciladores utilizados é pequeno. Cabe ressaltar que teoricamente o modelo é ergódico, uma vez que fisicamente podem-se considerar infinitas senóides chegando no receptor para formar a componente multipercurso. Mas, em implementações práticas do modelo deve-se cuidar para que um número mínimo de osciladores seja utilizado de forma a manter sua ergodicidade. O que as simulações mostraram é que 8 osciladores é um número insuficiente para tal propósito. O mesmo resultado já havia sido mostrado no Capítulo 3 por meio de resultados analíticos de médias temporais calculadas neste trabalho, onde também foi mostrado que esse número deveria ser pelo menos maior ou igual a 64. Neste momento, é importante salientar que nas simulações comparativas optou-se por escolher um número de osciladores igual a 8 por se tratar do mesmo número escolhido por Zheng em suas simulações. Porém, o autor (Zheng) só apresentou resultados de simulação de médias estatísticas. Finalmente, note que se 64 osciladores fossem utilizados, o modelo de Jakes modificado seria aproximadamente 24 vezes (3×8) mais lento que os modelos IDFT.

Finalmente, comparando os modelos de Dent e Zheng (ambos versões modificadas do modelo de Jakes), verifica-se que o primeiro tem a vantagem de ser ergódico independentemente do número de osciladores utilizados. Apresenta resultados satisfatórios (com relação a propriedades estatísticas) com o uso de 16 ou 32 osciladores, inclusive com correlação entre as partes real e imaginária igual a zero na origem. Comparando a Figura 3.18 à Figura 3.21 verifica-se que mesmo para 8 osciladores o modelo de Dent apresenta um ajuste melhor à curva de referência de função de autocorrelação. Por outro lado o modelo de Dent tem a desvantagem de oferecer um número limitado de componentes multipercurso, além de apresentar elevada correlação entre duas funções amostras e entre suas partes real e imaginária quando ocorre um deslocamento temporal entre as mesmas. Já o modelo de Zheng não apresenta limitações quanto ao número de funções amostras, além de apresentar funções amostras não correlacionadas para qualquer deslocamento temporal. Por

outro lado requer um número maior de osciladores para satisfazer a condição de ergodicidade.

Cabe a observação que o modelo de Jakes nas suas versões modificadas vem sendo amplamente utilizado por pesquisadores de diversos países há décadas. É sem dúvida o mais utilizado nesta área. Já o modelo de Smith e suas versões modificadas não são tão utilizados como o de Jakes. Porém, neste trabalho foi mostrado que os modelos IDFT (proposto e Smith modificado) apresentam vantagens significativas em relação aos modelos baseados em soma de senóides, e parecem ser a melhor alternativa na escolha de modelos de simulação de canal com desvanecimento multipercurso. Mesmo que alguma proposta de modificação no modelo de Jakes venha a torná-lo ergódico (independente do número de osciladores) e ao mesmo tempo com propriedades estatísticas corretas, como é o caso dos modelos IDFT, esse modelo leva a desvantagem de exigir um maior esforço computacional nas simulações devido à presença intrínseca de um somatório de osciladores na geração dos coeficientes de transmissão.

CAPÍTULO 7

CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foram apresentadas diversas formas de modelagem computacional de canal de comunicação móvel quanto à perda de percurso e ao desvanecimento rápido. Os modelos de perda de percurso apresentados são modelos consolidados cientificamente e tem sido amplamente utilizados. O mesmo pode ser dito sobre os modelos de desvanecimento rápido apresentados. O trabalho contribuiu para um aprofundamento no conhecimento de canais com desvanecimento Rayleigh e Rice e seus simuladores, e por apresentar um novo método de geração de coeficientes de transmissão em canal com desvanecimento rápido. O novo modelo apresentado foi validado por meio de análise analítica, numérica e comparativa.

Ficou ilustrado neste trabalho que os modelos IDFT apresentados são matematicamente corretos e computacionalmente eficientes e que são a melhor escolha para modelagem de canais com desvanecimento Rayleigh ou Rice, seja para simular componentes multipercurso correlacionadas ou não correlacionadas. Além disso, por apresentarem geração dos coeficientes de transmissão no domínio da frequência, apresentam facilidade de adaptação para simuladores de canais com presença de ângulo de elevação nas componentes (tridimensionais).

Para trabalhos futuros sugere-se o estudo de formas de modelagem computacional de canais com desvanecimento Nakagami, dos efeitos do somreamento sobre o sinal transmitido, assim como das formas de modelagem computacional do perfil atraso-potência presente em canal com desvanecimento Rayleigh e ou Rice.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] RICE, S. O. Mathematical Analysis of Random Noise. *Bell System Technical Journal*, vol 23, p. 282-332; Jul. 1944, vol 24, p. 46-156, Jan. 1945.
- [2] CLARKE, R. H. A statistical theory of mobile radio reception. *Bell System Technical Journal*, vol. 47, p. 957-1000, July 1968.
- [3] GANS, M. J. A power-spectral theory of propagation in the mobile-radio environment. *IEEE Transactions on Vehicular Technology*, vol. VT-21, no. 1, p. 27-38, Feb. 1972.
- [4] JAKES, W. C. *Microwave Mobile Communications*. New York: Wiley, 1974.
- [5] ARANGUREN, W. L. and LANGSETH, R. E. Baseband performance of a pilot diversity system with simulated Rayleigh fading signals and co-channel interference. *IEEE Transactions on Communications*, vol. COM-21, no. 11, p. 1248-1257, Nov. 1973.
- [6] SMITH, J. I. A computer generating multipath fading simulation for mobile radio. *IEEE Transactions on Vehicular Technology*, vol. VT-24, no. 3, p. 39-40, Aug. 1975.
- [7] DENT, P. G., BOTTOMLEY, E., and CROFT T. Jakes fading model revisited. *Electronics Letters*, vol. 29, no. 13, p. 1162-1163, June 1993.
- [8] PATZOLD, M., ULRICH, K., and LAUE, F. On the statistical properties of deterministic simulation models for mobile fading channels. *IEEE Transactions on Vehicular Technology*. Vol. 47, no 1, p. 254-269, Feb. 1998.
- [9] PATZOLD, M. and LAUE, F. Statistical properties of Jakes' fading channel simulator. *Proc. IEEE VTC'98*, vol. II, p. 712-718, Ottawa, May 1998.
- [10] PATZOLD, M., GARCIA, R., and LAUE, F. Design of high-speed simulation models for mobile fading channels by using table look-up techniques. *IEEE Transactions on Vehicular Technology*. vol. 49, no. 4, p. 1178-1190, July 2000.
- [11] LI, Y., GUAN, Y. L. Modified Jakes' model for simulating multiple uncorrelated fading waveforms. *Proc. IEEE ICC'00*, p. 46-49, 2000.

- [12] POP, M. and BEAULIEU, N. C. Limitations of sum-of-sinusoids fading channel simulators. *IEEE Transactions on Communications*, vol. 49, no. 4, p. 699-708, Apr. 2001.
- [13] XIAO, C., ZHENG, Y. R. and BEAULIEU, N. C. Second-order statistical properties of the WSS Jakes' fading channel simulator. *IEEE Transactions on Communications*, vol. 50, no. 6, p. 888-891, June 2002.
- [14] YOUNG, D. J. and BEAULIEU, N. C. On the generation of correlated Rayleigh random variates by inverse discrete Fourier transform. *1996 5th IEEE Int. Conf. on Universal Personal Communications Rec.*, Cambridge, MA, vol. 1, p. 231-235. Sept. 1996.
- [15] YOUNG, D. J. and BEAULIEU, N. C. The generation of correlated Rayleigh random variates by inverse discrete Fourier transform. *IEEE Transactions on Communications*, vol. 48, no. 7, p. 1114-1127, July 2000.
- [16] ZHENG Y. and XIAO, C. Simulation models with correct statistical properties for Rayleigh fading channels. *IEEE Transactions on Communications*, vol. 51, no. 6, p. 920-928, June 2003.
- [17] OPPENHEIM, A. V., SCHAFER, R. W., with BUCK, J. R. *Discrete-Time Signal Processing*, 2nd ed. New Jersey: Prentice Hall, 1999.
- [18] COOLEY, James W., TUKEY, John W. An algorithm for the machine computation of complex Fourier series. *Mathematics of Computation*, vol. 19, no. 90, p. 297-301, Apr. 1965.
- [19] FRIGO M. and JOHNSON, S. G. An adaptive software architecture for the FFT. *Proc. Int. Conf. Acoustics, Speech, and Signal Processing*, vol. 3, p. 1381-1384, 1998.
- [20] COST 207 – Digital Land Mobile Radio Communications. *Final Report*, Commission of the EC, 1989. Apud [23].
- [21] DAMOSSO, E. and CORREIA, L. M. Digital Mobile Radio Towards Future Generation Systems – *COST 231 Final Report*. COST Telecom Secretariat, European Commission, Brussels, Belgium, 1999.
- [22] BONEK, E. Antennas and Propagation. In: European Co-operation in the Field of Scientific and Technical Research. CORREIA, Luis. M. *Ericsson Internal Report*. Lisbon, May 2000.

- [23] European Co-operation in the Field of Scientific and Technical Research. “The COST 259 directional channel model – a stochastic model for spatial wideband channels”. *Ericsson Internal Report*, 2001.
- [24] SAMPEI, S. *Applications of Digital Wireless Technologies to Global Wireless Communications*. New Jersey: Prentice Hall PTR, 1997.
- [25] STEELE, R. *Mobile Radio Communications*. New York: IEEE Press, 1992.
- [26] STANCANELLI, E. M. G. *Receptores Rake em Canais com Desvanecimentos Rápidos e Seletivos em Frequência para Sistemas DS-CDMA*. São Paulo: Escola Politécnica da Universidade de São Paulo – EPUSP, 2004. 133 p. (Dissertação, Mestrado em Sistemas Eletrônicos).
- [27] KURAMOTO, André S. R. *Metodologias de Seleção de Sequências de Espalhamento para Sistemas DS/CDMA Quase Síncronos*. São Paulo: Escola Politécnica da Universidade de São Paulo – EPUSP, 2004. (Dissertação, Mestrado em Sistemas Eletrônicos, a ser publicada).
- [28] KURAMOTO, André S. R., ABRÃO, Taufik and JESZENSKY, Paul Jean E. Sets of sequences for QS-CDMA systems with interference cancellation over multipath Rayleigh fading channels. *2004 IEEE International Symposium on Spread Spectrum Techniques and Applications*. Sydney, Australia, Sept. 2004.
- [29] KURAMOTO, André S. R. *Análise de Desempenho de Sistemas QS-CDMA*. Londrina: Universidade Estadual de Londrina – UEL, 2002. (Trabalho de conclusão de curso).
- [30] ANGÉLICO, Bruno A. *Sistemas CDMA Multiportadora*. São Paulo: Escola Politécnica da Universidade de São Paulo – EPUSP, 2004. (Dissertação, Mestrado em Sistemas Eletrônicos, a ser publicada).
- [31] SILVA, Vanderlei, ABRÃO, Taufik and JESZENSKY, Paul Jean E. Statistically correct simulation models for the generation of multiple uncorrelated Rayleigh fading waveforms. *In 2004 IEEE International Symposium on Spread Spectrum Techniques and Applications*. Sydney, Australia, p. 472-476, Sept. 2004.
- [32] HATA, M. Empirical formula for propagation loss in land mobile radio services. *IEEE Transactions on Vehicular Technology*, vol . VT-29, no. 3, p. 317-325, Aug. 1980.

- [33] MOGENSEN, P. E. et al. Urban area radio propagation measurements at 955 and 1845 MHz for small and micro cells. *IEEE Global Commun. Conf.*, Phoenix, AZ, p. 1297-1302, Dec. 1991.
- [34] XIA, H. H. A simplified analytical model for predicting path loss in urban and suburban environments. *IEEE Transactions on Vehicular Technology*, vol . 46, no. 4, p. 1040-44, Nov. 1997.
- [35] OKUMURA, Y. et al. Field strength and its variability in UHF and VHF land-mobile radio service. *Rev. Elec. Commun. Lab.*, vol. 16, 1968. Apud [32].
- [36] WALFISCH, J. and BERTONI, H. L. A theoretical model of UHF propagation in urban environments. *IEEE Transactions on Antennas and Propagation*, vol. 36, no. 12, p. 1788-96, Dec. 1988.
- [37] IKEGAMI, F. Analysis of multipath propagation structure in urban mobile radio environments. *IEEE Transactions on Antennas and Propagation*, vol. AP-28, no. 4, p. 531-537, July 1980.
- [38] XIA, H. H. and BERTONI, H. L. Diffraction of cylindrical and plane waves by an array of absorbing half screens. *IEEE Transactions on Antennas and Propagation*, vol. 40, p. 170-177, Feb. 1992. Apud [34].
- [39] XIA, H. H. Multiple knife-edge diffraction and radio propagations in urban environments. Ph.D. dissertation, Polytech. Univ., Brooklyn, NY, Sept. 1990. Apud [34].
- [40] MACIEL, L. R., BERTONI, H. L., and XIA, H. H. Unified approach to prediction of propagations over buildings for all ranges of base station antenna height. *IEEE Transactions on Vehicular Technology*, vol . 42, p. 41-45, Feb. 1993. Apud [34].
- [41] BRODHAGE, H., HORMUTH, W. *Planejamento e Cálculo de Radioenlaces*. 10 ed. São Paulo: Editora Pedagógica e Universitária Ltda, 1981.
- [42] STUBER, G. L. *Principles of Mobile Communication*, 2nd ed., Massachusetts: Kluwer Academic Publishers, 2001.
- [43] PAPOULIS, A. *Probability, Random Variables, and Stochastic Process*. New York: McGraw-Hill, Inc, 1991.

- [44] LEE, W. C. Y. *Mobile Communications Engineering*, New York: McGraw-Hill, 1982.
- [45] JAKES, W. C. Comparison of mobile radio transmission at UHF and X band," *IEEE Transactions on Vehicular Technology*, vol. VT-16, no. 1, p. 10-14, Oct. 1967.
- [46] AULIN, Tor. A modified model for the fading signal at a mobile radio channel. *IEEE Transactions on Vehicular Technology*, vol. VT-28, no 3, p. 182-203, Aug. 1979.
- [47] PÄTZOLD, Matthias, et all. A new and optimal method for the derivation of deterministic simulation models for mobile radio channels. *IEEE 46th Vehicular Technology Conference, 'Mobile Technology for the Human Race'*, vol 3, no 28, p. 1423-1427, May 1996.
- [48] PRASAD, Ramjee, KEGEL, Adriaan. Effects of Rician faded and log-normal shadowed signals on spectrum efficiency in microcellular radio. *IEEE Transactions on Vehicular Technology*, vol. 42, no 3, p. 274-281, Aug. 1993.
- [49] BULTITUDE, Robert J., BEDAL Keith. Propagation characteristics on microcellular urban mobile radio channels at 910 MHz. *IEEE Journal on Selected Areas in Communications*, vol.7, no. 1, p. 31-39, Jan. 1989.
- [50] SECORD, Normam P., et all. Analysis and measurement of FM click rate in slow Rician fading. *IEEE Transactions on Vehicular Technology*, vol. 42, no 2, p.197-204, May 1993.
- [51] BECKMANN, P. *Probability in Communications Engineering*. Harcourt, Brace & World, Inc.,NY, 1967.
- [52] NAKAGAMI, Minoru. The m -Distribution – A general formula of intensity distribution of rapid fading. *In Statistical Methods in Radio Wave Propagation*, California, LA, June, 1958, p. 3-36, HOFFMAN, W. C. (Ed), Pergamon Press, NY, 1960.
- [53] CHARASH, U. Reception through Nakagami fading multipath channels with random delays. *IEEE Transactions on Communications*, vol. COM-27, no 4, Apr. 1979.
- [54] SUZUKI, Hirofumi. A statistical model for urban radio propagation. *IEEE Transactions on Communications*, vol. COM-25, no 7, Apr. 1977.

- [55] ABBAS, S. A., SHEIKH, A. U. A geometric theory of Nakagami fading multipath mobile radio channel with physical interpretations. *In IEEE 46th Vehicular Technology Conference*, vol. 2, p. 637-641, 1996.
- [56] YACOUB, Michel D., BAUTISTA, José E. V., and GUEDES, Leonardo G. R. On higher order statistics of the Nakagami- m distribution. *IEEE Transactions on Vehicular Technology*, vol. 48, no. 3, p. 790-794, May 1999.
- [57] YACOUB, Michel D. The η - μ Distribution: a general fading distribution. *In IEEE 52nd Vehicular Technology Conference*, VTS-Fall VTC 2000, vol. 2, p. 872-877, Sept. 2000.
- [58] YACOUB, Michel D. The κ - μ Distribution: a general fading distribution. *In IEEE 54th Vehicular Technology Conference*, VTC 2001 Fall, vol. 3, p. 1427-1431, Oct. 2001.
- [59] FRAIDENRAICH, Gustavo and YACOUB, Michel D. The λ - μ general fading distribution. *In XX Simpósio Brasileiro de Telecomunicações – SBT'03*, Rio de Janeiro, RJ, Oct. 2003.
- [60] YACOUB, Michel D, et al. The Symmetrical η - μ Distribution. *In 2004 IEEE 15th International Symposium on Personal, Indoor and Mobile Radio Communications, Barcelona, Spain*, Sept. 2004.
- [61] ABRÃO, T. *Canceladores de Interferência Multiusuário Aplicados a Sistemas DS/CDMA de Múltipla Taxa*. São Paulo: Escola Politécnica da Universidade de São Paulo – EPUSP, 2001. 363p. (Tese, Doutorado em Sistemas Eletrônicos).
- [62] MARQUES, Paulo, FERNANDES, José, NEVES, José. Complex impulse response modeling for wideband channels. *48th IEEE Vehicular Technology Conference – VTC'98*, vol. 2, p. 702-706, May 1998.
- [63] LECOURS, Michel, et all. Statistical modeling of the received signal envelope in a mobile radio channel. *IEEE Transactions on Vehicular Technology*, vol. 37, no 4, p. 204-212, Nov. 1988.
- [64] GLAZUNOV, Andres A., ASPLUND, Henrik, BERG, Jan-Erick. Statistical analysis of measured short-term impulse response functions of 1.88 GHz radio channels in Stockholm with corresponding channel model. *IEEE 50th Vehicular Technology Conference – VTC'99 Fall*, vol. 1, p. 107-111, Sept. 1999.

- [65] ANGÉLICO, Bruno A., ABRÃO, Taufik, JESZENSKY, Paul Jean E. Desempenho de um sistema MC-CDMA em canal com desvanecimentos Rayleigh correlacionados na frequência. *Revista do Instituto Nacional de Telecomunicações*, vol. 6, no. 2, p. 1-8, Dez. 2003.
- [66] MEYER, Carl D. *Matrix Analysis and Applied Linear Algebra*. Society for Industrial & Applied Mathematics: Philadelphia, 718 p, 2000.
- [67] European Co-operation in the Field of Scientific and Technical Research. “The COST 259 directional channel model – a Matlab implementation”. *Ericsson Internal Report*, 2001.
- [68] COUCH II, L. W. *Digital and Analog Communication Systems*, 5th ed. New Jersey: Prentice Hall, 1993.
- [69] LATHI, B. P. *Modern Digital and Analog Communications Systems*. 2nd ed. Philadelphia: Holt, Rinehart, and Winston, 1989.

APÊNDICE A

PROCESSOS ALEATÓRIOS

O objetivo deste apêndice não é contemplar todos os tópicos sobre processos aleatórios e sim apresentar somente o conteúdo necessário para o entendimento do trabalho quanto à notação e critérios utilizados.

A.1 VARIÁVEIS ALEATÓRIAS

O valor esperado de uma variável aleatória (RV, *random variable*) x com função densidade de probabilidade $f_x(x)$ por definição é dado por [43]

$$E\{x\} \triangleq \int_{-\infty}^{\infty} x f_x(x) dx \quad (\text{A.1})$$

onde $E\{\cdot\}$ é chamado de operador esperança.

A variância de x é dada por

$$\sigma_x^2 = E\{x^2\} - E^2\{x\} \quad (\text{A.2})$$

A correlação cruzada entre duas RVs x e y é dada por

$$R_{xy} = E\{xy\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_{xy}(x, y) dx dy \quad (\text{A.3})$$

A covariância entre x e y é dada por

$$C_{xy} = E\{xy\} - E\{x\}E\{y\} \quad (\text{A.4})$$

As variáveis aleatórias x e y são ditas ortogonais quando a correlação cruzada entre as duas é igual a zero. Já quando a covariância é igual a zero, x e y são ditas não correlacionadas.

Uma maneira conveniente de avaliar a correlação entre duas RVs é através da normalização da covariância dada por

$$r_{xy} = \frac{C_{xy}}{\sigma_x^2 \sigma_y^2} \quad (\text{A.5})$$

onde r_{xy} também é chamado de coeficiente de correlação [43]. Pode-se mostrar que $|r_{xy}| \leq 1$.

A.2 PROCESSOS ALEATÓRIOS

Um processo aleatório $x(\zeta, t)$ pode ser definido como uma família de funções no tempo t dependendo de um parâmetro ζ ou, equivalentemente uma função de t e ζ . O domínio de ζ é o conjunto de todos os resultados possíveis para um experimento e o domínio de t é o conjunto dos números reais [43]. Frequentemente a notação $x(t)$ é utilizada para representar um processo aleatório, omitindo sua dependência de ζ .

Um processo aleatório tem as seguintes interpretações:

- Se ζ e t são variáveis, então $x(t)$ é uma família de funções $x(\zeta, t)$;
- Se ζ é fixo t é variável, então $x(t)$ é uma simples função no tempo ou função amostra;
- Se ζ é variável t é fixo, então $x(t)$ é uma variável aleatória;
- Se ζ e t são fixos, então $x(t)$ é um número.

De acordo com as interpretações acima, um processo aleatório é um conjunto de funções amostras com um número incontável de variáveis aleatórias, sendo uma para cada valor de t .

São chamadas de médias estatísticas (*ensemble averages*) as propriedades estatísticas apresentadas pelo processo que podem ser calculadas através de suas variáveis aleatórias. Para tal utiliza-se o operador esperança. São chamadas de médias temporais (*time averages*) as propriedades calculadas sobre uma função amostra do processo. Para o cálculo das médias temporais utiliza-se o operador média temporal

que é definido por

$$\langle (x(t)) \rangle \triangleq \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T (x(t)) dt \right) \quad \text{e} \quad \langle [x[n]] \rangle \triangleq \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{n=0}^{N-1} [x[n]] \right) \quad (\text{A.6})$$

para os casos contínuo e discreto, respectivamente. Note que a notação $x(t)$ representa uma função amostra do processo $x(t)$.

Para evitar ambigüidades na interpretação do texto apresentado neste trabalho, faz-se necessário definir alguns termos utilizados no decorrer do mesmo:

- **Médias estatísticas (*ensemble averages*):** o conjunto das propriedades estatísticas apresentadas por uma variável aleatória ou processo aleatório calculadas por meio do operador esperança. Exemplo: esperança, função de autocorrelação e função de autocovariância em um processo aleatório Gaussiano;
- **Médias temporais (*time averages*):** o conjunto das propriedades apresentadas por uma função amostra de um processo aleatório calculadas por meio do operador média temporal. Exemplo: valor médio temporal, função de autocorrelação temporal e função de autocovariância temporal em um processo aleatório Gaussiano;
- **Média estatística:** quando utilizado, esse termo se refere a um dos membros presentes no conjunto médias estatísticas. Exemplo: “A função de autocorrelação é uma média estatística”;
- **Média temporal:** quando utilizado, esse termo se refere a um dos membros presentes no conjunto médias temporais. Exemplo: “A função de autocorrelação temporal é uma média temporal”;
- **Valor médio:** o valor médio de uma variável aleatória ou processo aleatório é denominado esperança. Já o valor médio de uma função amostra desse processo é denominado valor médio temporal.

Para processos físicos, certamente que as médias temporais são mais facilmente medidas que as estatísticas, pois no segundo caso será necessário tomar em cada instante de tempo medidas de diversas funções amostras. Pode então ser conveniente

que as propriedades estatísticas de um processo aleatório possam ser determinadas através de uma simples função amostra do processo, ou seja, que as médias estatísticas e temporais sejam iguais. Nesse caso o processo é chamado ergódico.

A maioria dos autores [51],[68],[69] (principalmente em livros de engenharia) consideram que um processo é ergódico quando com probabilidade igual 1 a média temporal é igual a média estatística [51], ou seja,

$$P\{(média\ temporal) = (média\ estatística)\} = 1 \quad (A.7)$$

Note que para que a igualdade (A.7) seja válida, a média temporal em questão tem que ser a mesma para todas as funções amostras do processo. Se a média em questão for o valor médio, então o processo é dito ergódico em média, se for a função de autocorrelação, o processo é dito ergódico em autocorrelação, e assim para todas as médias possíveis em um processo.

A.2.1 MÉDIAS ESTATÍSTICAS

$$\text{Valor médio ou esperança: } E\{x(t)\} \triangleq \int_{-\infty}^{\infty} x f_x(x,t) dx \quad (A.8)$$

$$\text{Autocorrelação: } R_x(t_1, t_2) = E\{x(t_1)x^*(t_2)\} \quad (A.9)$$

$$\text{Autocovariância: } C_x(t_1, t_2) = R_x(t_1, t_2) - E\{x(t_1)\}E\{x^*(t_2)\} \quad (A.10)$$

$$\text{Coeficiente de correlação: } r_x(t_1, t_2) = \frac{C_x(t_1, t_2)}{\sqrt{C_x(t_1, t_1)C_x(t_2, t_2)}} \quad (A.11)$$

$$\text{Correlação cruzada: } R_{xy}(t_1, t_2) = E\{x(t_1)y^*(t_2)\} \quad (A.12)$$

$$\text{Covariância cruzada: } C_x(t_1, t_2) = R_{xy}(t_1, t_2) - E\{x(t_1)\}E\{y^*(t_2)\} \quad (A.13)$$

A.2.2 MÉDIAS TEMPORAIS PARA PROCESSOS WSS

Valor médio temporal: $\langle\langle x(t) \rangle\rangle \triangleq \lim \left(\frac{1}{T} \int_0^T x(t) dt \right)$ (A.14)

Autocorrelação temporal: $\bar{R}_x(\tau) = \langle\langle x(t)x^*(t+\tau) \rangle\rangle$ (A.15)

Autocovariância temporal: $\bar{C}_x(\tau) = \bar{R}_x(\tau) - \langle\langle x(t) \rangle\rangle \langle\langle x^*(t) \rangle\rangle$ (A.16)

Correlação cruzada temporal: $\bar{R}_{xy}(\tau) = \langle\langle x(t)y^*(t+\tau) \rangle\rangle$ (A.17)

Covariância cruzada temporal: $\bar{C}_{xy}(\tau) = \bar{R}_{xy}(\tau) - \langle\langle x(t) \rangle\rangle \langle\langle y^*(t) \rangle\rangle$ (A.18)

Covariância temporal normalizada: $\bar{C}_{xy}^n(\tau) = \frac{\bar{C}_{xy}(\tau)}{\sqrt{\bar{C}_x(0)\bar{C}_y(0)}}$ (A.19)

APÊNDICE B

CÁLCULOS DE PROPRIEDADES ESTATÍSTICAS DOS MODELOS

B.1 CÁLCULO DAS PROPRIEDADES ESTATÍSTICAS DO MODELO DE CLARKE

B.1.1 MÉDIAS ESTATÍSTICAS

Seja o processo aleatório $c(t)$ definido em (3.9)

$$c(t) = E_0 \sum_{n=1}^M A_n e^{j(\omega_n t + \phi_n)}, \quad (\text{B.1})$$

onde A_n , α_n e ϕ_n são variáveis aleatórias independentes para qualquer n e o conjunto de variáveis $\{\phi_n\}$ são independentes entre si e uniformemente distribuídas de 0 a 2π .

A esperança de $c(t)$ é dada por

$$\begin{aligned} E\{c(t)\} &= E_0 \sum_{n=1}^M E\{A_n\} E\{e^{j(\omega_n t)}\} \underbrace{E\{e^{j\phi_n}\}}_{=0} = 0 \\ \Rightarrow E\{\text{Re}\{c(t)\}\} &= 0 = E\{\text{Im}\{c(t)\}\} \end{aligned} \quad (\text{B.2})$$

O valor médio quadrático de $c(t)$ é dado por

$$\begin{aligned} E\{|c(t)|^2\} &= E\{c(t)c^*(t)\} = E_0^2 E\left\{\sum_{n=1}^M \sum_{k=1}^M A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)}\right\} \\ &= E_0^2 \sum_{n=1}^M \sum_{k=1}^M E\{A_n A_k^*\} E\{e^{j(\omega_n - \omega_k)t}\} E\{e^{j(\phi_n - \phi_k)}\} \end{aligned} \quad (\text{B.3})$$

mas,

$$E\{e^{j(\omega_n - \omega_k)t}\} = 1, \quad n = k \quad \text{e} \quad E\{e^{j(\phi_n - \phi_k)}\} = \begin{cases} 1, & n = k \\ 0, & n \neq k \end{cases} \quad (\text{B.4})$$

logo,

$$E\{|c(t)|^2\} = E_0^2 \sum_{n=1}^M E\{|A_n|^2\} \quad (\text{B.5})$$

Assumindo que as variáveis aleatórias pertencentes ao conjunto $\{A_n\}$ têm o mesmo valor médio quadrático $E\{|A_n|^2\} = Q_A$, então de (B.5), tem-se

$$E\{|c(t)|^2\} = E_0^2 M Q_A \quad (\text{B.6})$$

A variância da parte real de $c(t)$ pode ser calculada utilizando (B.2) e (B.4), considerando que

$$\text{Re}\{c(t)\} = \frac{1}{2}(c(t) + c^*(t)) \quad (\text{B.7})$$

Assim,

$$\begin{aligned} \sigma_R^2 &= E\left\{\left(\text{Re}\{c(t)\}\right)^2\right\} - E^2\left\{\text{Re}\{c(t)\}\right\} \\ &= E\left\{\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t + \phi_n)} + A_n^* e^{-j(\omega_n t + \phi_n)}\right) \left(A_k e^{j(\omega_k t + \phi_k)} + A_k^* e^{-j(\omega_k t + \phi_k)}\right)\right\} \\ &= \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M E\left\{A_n A_k e^{j(\omega_n + \omega_k)t} e^{j(\phi_n + \phi_k)} + A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} + \right. \\ &\quad \left. A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} + A_n^* A_k^* e^{-j(\omega_n + \omega_k)t} e^{-j(\phi_n + \phi_k)}\right\} \\ &= \frac{E_0^2}{4} \sum_{n=1}^M E\{|A_n|^2 + |A_n|^2\} \\ &= \frac{E_0^2}{2} \sum_{n=1}^M E\{|A_n|^2\} \end{aligned} \quad (\text{B.8})$$

A variância da parte imaginária de $c(t)$ pode ser calculada utilizando (B.2) e (B.4) e considerando que

$$\text{Im}\{c(t)\} = \frac{1}{2j}(c(t) - c^*(t)) \quad (\text{B.9})$$

Assim,

$$\begin{aligned}
\sigma_1^2 &= E \left\{ \left(\text{Im} \{ \mathbf{c}(t) \} \right)^2 \right\} - E^2 \{ \text{Im} \{ \mathbf{c}(t) \} \} \\
&= E \left\{ -\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t + \phi_n)} - A_n^* e^{-j(\omega_n t + \phi_n)} \right) \left(A_k e^{j(\omega_k t + \phi_k)} - A_k^* e^{-j(\omega_k t + \phi_k)} \right) \right\} \\
&= -\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M E \left\{ A_n A_k e^{j(\omega_n + \omega_k)t} e^{j(\phi_n + \phi_k)} - A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} - \right. \\
&\quad \left. A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} + A_n^* A_k^* e^{-j(\omega_n + \omega_k)t} e^{-j(\phi_n + \phi_k)} \right\} \\
&= -\frac{E_0^2}{4} \sum_{n=1}^M E \left\{ -|A_n|^2 - |A_n|^2 \right\} \\
&= \frac{E_0^2}{2} \sum_{n=1}^M E \left\{ |A_n|^2 \right\} = \sigma_R^2
\end{aligned} \tag{B.10}$$

Definindo o valor médio quadrático de $\mathbf{c}(t)$, apresentado em (B.6) como

$$E \left\{ |\mathbf{c}(t)|^2 \right\} = E_0^2 M Q_A \triangleq 2\sigma^2 \tag{B.11}$$

então

$$\sigma_R^2 = \sigma_1^2 = \sigma^2 \tag{B.12}$$

A função de autocorrelação de $\mathbf{c}(t)$ é dada por

$$\begin{aligned}
R_c(t_1, t_2) &= E \left\{ \mathbf{c}^*(t_1) \mathbf{c}(t_2) \right\} \\
&= E_0^2 \sum_{n=1}^M \sum_{k=1}^M E \left\{ A_n^* A_k \right\} E \left\{ e^{j(\omega_k t_2 - \omega_n t_1)} \right\} E \left\{ e^{j(\phi_k - \phi_n)} \right\} \\
&= E_0^2 \sum_{n=1}^M E \left\{ |A_n|^2 \right\} E \left\{ e^{j\omega_n(t_2 - t_1)} \right\} \\
&= E_0^2 \sum_{n=1}^M E \left\{ |A_n|^2 \right\} E \left\{ e^{j2\pi f_m \tau \cos \alpha_n} \right\}, \text{ onde } \tau = t_2 - t_1 \\
&= E_0^2 \sum_{n=1}^M E \left\{ |A_n|^2 \right\} \int_{-\pi}^{+\pi} f_\alpha(\alpha_n) e^{j2\pi f_m \tau \cos \alpha_n} d\alpha_n
\end{aligned} \tag{B.13}$$

Para $f_\alpha(\alpha_n) = \frac{1}{2\pi}$, a integral em (B.13) pode ser representada por uma função de Bessel de primeira classe e ordem zero $J_0(\cdot)$. Desta forma, utilizando (B.11), tem-se

$$\begin{aligned}
R_c(\tau) &= E_0^2 \sum_{n=1}^M E \left\{ |A_n|^2 \right\} J_0(2\pi f_m \tau) \\
&= 2\sigma^2 J_0(2\pi f_m \tau)
\end{aligned} \tag{B.14}$$

A autocorrelação da parte real é dada por

$$\begin{aligned}
g_R(t_1, t_2) &= E\left\{\operatorname{Re}\{c(t_1)\}\operatorname{Re}\{c(t_2)\}\right\} \tag{B.15} \\
&= E\left\{\frac{E_0^2}{4}\sum_{n=1}^M\sum_{k=1}^M\left(A_n e^{j(\omega_n t_1 + \phi_n)} + A_n^* e^{-j(\omega_n t_1 + \phi_n)}\right)\left(A_k e^{j(\omega_k t_2 + \phi_k)} + A_k^* e^{-j(\omega_k t_2 + \phi_k)}\right)\right\} \\
&= \frac{E_0^2}{4}\sum_{n=1}^M\sum_{k=1}^M E\left\{A_n A_k e^{j(\omega_n t_1 + \omega_k t_2)} e^{j(\phi_n + \phi_k)} + A_n A_k^* e^{j(\omega_n t_1 - \omega_k t_2)} e^{j(\phi_n - \phi_k)} + \right. \\
&\quad \left. A_n^* A_k e^{j(\omega_k t_2 - \omega_n t_1)} e^{j(\phi_k - \phi_n)} + A_n^* A_k^* e^{-j(\omega_n t_1 + \omega_k t_2)} e^{-j(\phi_n + \phi_k)}\right\} \\
&= \frac{E_0^2}{4}\sum_{n=1}^M E\left\{|A_n|^2\right\}\left(E\left\{e^{j\omega_n(t_2 - t_1)}\right\} + E\left\{e^{-j\omega_n(t_2 - t_1)}\right\}\right) \\
&= \frac{E_0^2}{4}\sum_{n=1}^M E\left\{|A_n|^2\right\}\left(E\left\{e^{j2\pi f_m \tau \cos \alpha_n}\right\} + E\left\{e^{-j2\pi f_m \tau \cos \alpha_n}\right\}\right), \text{ onde } \tau = t_2 - t_1 \\
&= \frac{E_0^2}{4}\sum_{n=1}^M E\left\{|A_n|^2\right\}\left(J_0(2\pi f_m \tau) + J_0(-2\pi f_m \tau)\right)
\end{aligned}$$

Observando que $J_0(\cdot)$ é uma função par e utilizando (B.11), tem-se

$$g_R(\tau) = \sigma^2 J_0(2\pi f_m \tau) \tag{B.16}$$

A autocorrelação da parte imaginária é dada por

$$\begin{aligned}
g_I(t_1, t_2) &= E\left\{\operatorname{Im}\{c(t_1)\}\operatorname{Im}\{c(t_2)\}\right\} \tag{B.17} \\
&= E\left\{-\frac{E_0^2}{4}\sum_{n=1}^M\sum_{k=1}^M\left(A_n e^{j(\omega_n t_1 + \phi_n)} - A_n^* e^{-j(\omega_n t_1 + \phi_n)}\right)\left(A_k e^{j(\omega_k t_2 + \phi_k)} - A_k^* e^{-j(\omega_k t_2 + \phi_k)}\right)\right\} \\
&= -\frac{E_0^2}{4}\sum_{n=1}^M\sum_{k=1}^M E\left\{A_n A_k e^{j(\omega_n t_1 + \omega_k t_2)} e^{j(\phi_n + \phi_k)} - A_n A_k^* e^{j(\omega_n t_1 - \omega_k t_2)} e^{j(\phi_n - \phi_k)} - \right. \\
&\quad \left. A_n^* A_k e^{j(\omega_k t_2 - \omega_n t_1)} e^{j(\phi_k - \phi_n)} + A_n^* A_k^* e^{-j(\omega_n t_1 + \omega_k t_2)} e^{-j(\phi_n + \phi_k)}\right\} \\
&= \frac{E_0^2}{4}\sum_{n=1}^M E\left\{|A_n|^2\right\}\left(E\left\{e^{j\omega_n(t_2 - t_1)}\right\} - E\left\{e^{-j\omega_n(t_2 - t_1)}\right\}\right) \\
&= \frac{E_0^2}{4}\sum_{n=1}^M E\left\{|A_n|^2\right\}\left(E\left\{e^{j2\pi f_m \tau \cos \alpha_n}\right\} - E\left\{e^{-j2\pi f_m \tau \cos \alpha_n}\right\}\right), \text{ onde } \tau = t_2 - t_1 \\
&= \sigma^2 J_0(2\pi f_m \tau)
\end{aligned}$$

Conseqüentemente,

$$g_I(\tau) = g_R(\tau) = g(\tau) = \sigma^2 J_0(2\pi f_m \tau) \quad (\text{B.18})$$

A correlação cruzada entre as partes real e imaginária de $c(t)$ é dada por

$$\begin{aligned} h(t_1, t_2) &= E\{\text{Re}\{c(t_1)\}\text{Im}\{c(t_2)\}\} \quad (\text{B.19}) \\ &= E\left\{\frac{E_0^2}{4j} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t_1 + \phi_n)} + A_n^* e^{-j(\omega_n t_1 + \phi_n)}\right) \left(A_k e^{j(\omega_k t_2 + \phi_k)} - A_k^* e^{-j(\omega_k t_2 + \phi_k)}\right)\right\} \\ &= \frac{E_0^2}{4j} \sum_{n=1}^M \sum_{k=1}^M E\left\{A_n A_k e^{j(\omega_n t_1 + \omega_k t_2)} e^{j(\phi_n + \phi_k)} - A_n A_k^* e^{j(\omega_n t_1 - \omega_k t_2)} e^{j(\phi_n - \phi_k)} + \right. \\ &\quad \left. A_n^* A_k e^{j(\omega_k t_2 - \omega_n t_1)} e^{j(\phi_k - \phi_n)} - A_n^* A_k^* e^{-j(\omega_n t_1 + \omega_k t_2)} e^{-j(\phi_n + \phi_k)}\right\} \\ &= \frac{E_0^2}{4j} \sum_{n=1}^M E\{|A_n|^2\} \left(E\{e^{j\omega_n(t_2 - t_1)}\} - E\{e^{-j\omega_n(t_2 - t_1)}\}\right) \\ &= \frac{E_0^2}{4j} \sum_{n=1}^M E\{|A_n|^2\} \left(E\{e^{j2\pi f_m \tau \cos \alpha_n}\} - E\{e^{-j2\pi f_m \tau \cos \alpha_n}\}\right), \text{ onde } \tau = t_2 - t_1 \\ &= \frac{E_0^2}{4j} \sum_{n=1}^M E\{|A_n|^2\} \left(J_0(2\pi f_m \tau) - J_0(-2\pi f_m \tau)\right) \\ &\Rightarrow h(\tau) = 0 \end{aligned}$$

Como as partes real e imaginária têm valor médio igual a zero, a correlação cruzada e a covariância são iguais. Conseqüentemente, pode se afirmar que as partes real e imaginária são não correlacionadas.

B.1.2 MÉDIAS TEMPORAIS

O valor médio temporal de uma função amostra de $c(t)$ é dado por

$$\begin{aligned} \langle\langle c(t) \rangle\rangle &= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T c(t) dt \right) = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T E_0 \sum_{n=1}^M A_n e^{j(\omega_n t + \phi_n)} dt \right) \\ &= E_0 \sum_{n=1}^M A_n \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T e^{j(\omega_n t + \phi_n)} dt \right) = 0 \quad (\text{B.20}) \\ &\Rightarrow \langle\langle \text{Re}\{c(t)\} \rangle\rangle = 0 = \langle\langle \text{Im}\{c(t)\} \rangle\rangle \end{aligned}$$

A função de autocorrelação temporal referente a uma função amostra de $c(t)$ é dada

por

$$\begin{aligned}
\bar{R}_c(\tau) &= \left\langle (c^*(t)c(t+\tau)) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T (c^*(t)c(t+\tau)) dt \right) \\
&= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T E_0^2 \sum_{n=1}^M \sum_{k=1}^M A_n^* A_k e^{-j(\omega_n t + \phi_n)} e^{j(\omega_k(t+\tau) + \phi_k)} dt \right) \\
&= E_0^2 \sum_{n=1}^M \sum_{k=1}^M A_n^* A_k e^{j\omega_k \tau} e^{j(\phi_k - \phi_n)} \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T e^{j(\omega_k - \omega_n)t} dt \right) \\
&= E_0^2 \sum_{k=1}^M |A_k|^2 e^{j\omega_k \tau} \\
&= E_0^2 \sum_{k=1}^M |A_k|^2 e^{j2\pi f_m \tau \cos \alpha_k}
\end{aligned} \tag{B.21}$$

onde o símbolo “—” (sobre o caractere que identifica a função) indica média temporal. Note que

$$\bar{R}_c(0) = E_0^2 \sum_{k=1}^M |A_k|^2 = ME_0^2 \left(\frac{1}{M} \sum_{k=1}^M |A_k|^2 \right) = ME_0^2 Q_A = 2\sigma^2 \tag{B.22}$$

Agora considere a função $y(k) = e^{j2\pi f_m \tau \cos \alpha_k}$ da RV α_k e a seguinte afirmação

$$\lim_{M \rightarrow \infty} \left(\frac{1}{M} \sum_{k=1}^M e^{j2\pi f_m \tau \cos \alpha_k} \right) = \frac{1}{2\pi} \int_{-\pi}^{+\pi} e^{j2\pi f_m \tau \cos \alpha_k} d\alpha_k = J_0(2\pi f_m \tau) \tag{B.23}$$

O limite do somatório em (B.23) representa a média de $y(k)$. Por outro lado a integral em (B.23) também representa a média de $y(k)$, já que a pdf de α_k é igual a $1/(2\pi)$. Esta integral também é a definição da função de Bessel de primeira classe e ordem zero. Conseqüentemente, o limite em (B.23) pode ser representado por esta função de Bessel.

Em seu modelo, Clarke considerou que todas as amplitudes das M componentes de onda são comuns e iguais a 1. Assim, utilizando (B.23), (B.21) vem a ser

$$\begin{aligned}
\bar{R}_c(\tau) &= E_0^2 \sum_{k=1}^M e^{j2\pi f_m \tau \cos \alpha_k} = E_0^2 M \frac{1}{M} \sum_{k=1}^M e^{j2\pi f_m \tau \cos \alpha_k} \\
&= 2\sigma^2 J_0(2\pi f_m \tau) = R_c(\tau), \quad M \rightarrow \infty
\end{aligned} \tag{B.24}$$

Numericamente é possível mostrar que a equação (B.21) converge para (B.24) mesmo que as componentes de onda tenham amplitudes A_n aleatórias. A Figura B.1 ilustra (B.21) para A_n uniformemente distribuída no intervalo $[0,1]$ (gráfico superior) e Gaussiana com média 0 e variância unitária (gráfico inferior), em ambos os casos com o valor médio quadrático de $c(t)$ igual a 1. À medida que o valor de M aumenta a função converge para a função de referência.

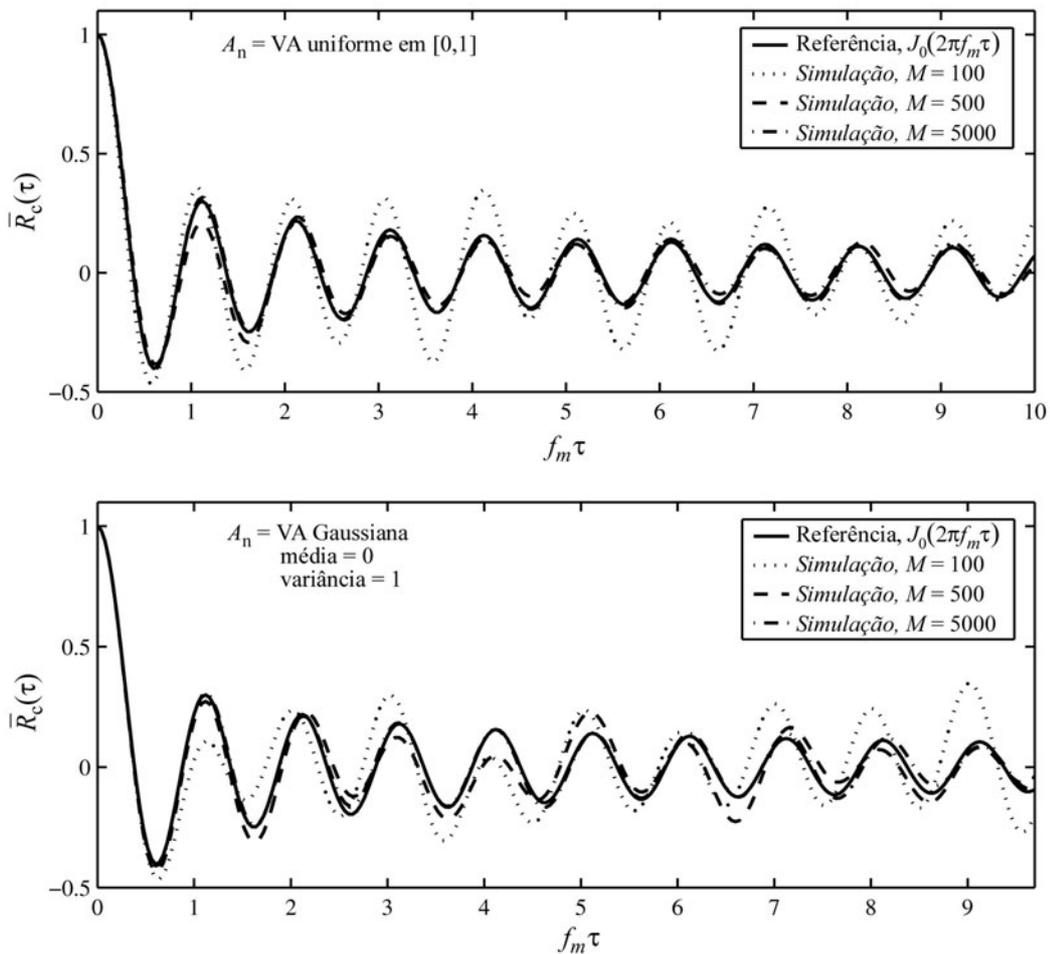


Figura B.1: Convergência da função de autocorrelação temporal quando as amplitudes das componentes de onda no modelo de Clarke são aleatórias. Notação: VA = variável aleatória.

A função de autocorrelação temporal referente à parte real de uma função amostra de $c(t)$ é dada por

$$\begin{aligned}
\bar{g}_R(\tau) &= \left\langle \left(\text{Re}\{c(t)\} \text{Re}\{c(t+\tau)\} \right) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \left(\text{Re}\{c(t)\} \text{Re}\{c(t+\tau)\} \right) dt \right) \quad (\text{B.25}) \\
&= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t + \phi_n)} + A_n^* e^{-j(\omega_n t + \phi_n)} \right) \left(A_k e^{j(\omega_k (t+\tau) + \phi_k)} + A_k^* e^{-j(\omega_k (t+\tau) + \phi_k)} \right) dt \right) \\
&= \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left\{ A_n A_k e^{j(\omega_n + \omega_k)t} e^{j(\phi_n + \phi_k)} e^{j\omega_k \tau} + A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} + \right. \\
&\quad \left. A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} + A_n^* A_k^* e^{-j(\omega_n + \omega_k)t} e^{-j(\phi_n + \phi_k)} e^{-j\omega_k \tau} \right\} dt \\
&= \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left(A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} + A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} \right) dt \\
&= \frac{E_0^2}{4} \left(\sum_{k=1}^M |A_k|^2 e^{-j\omega_k \tau} + \sum_{k=1}^M |A_k|^2 e^{j\omega_k \tau} \right)
\end{aligned}$$

De (B.21), percebe-se que

$$\bar{g}_R(\tau) = \frac{1}{2} \bar{R}_c(\tau) \quad (\text{B.26})$$

A função de autocorrelação temporal referente à parte imaginária de uma função amostra de $c(t)$ é dada por

$$\begin{aligned}
\bar{g}_I(\tau) &= \left\langle \left(\text{Im}\{c(t)\} \text{Im}\{c(t+\tau)\} \right) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \left(\text{Im}\{c(t)\} \text{Im}\{c(t+\tau)\} \right) dt \right) \quad (\text{B.27}) \\
&= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T -\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t + \phi_n)} - A_n^* e^{-j(\omega_n t + \phi_n)} \right) \left(A_k e^{j(\omega_k (t+\tau) + \phi_k)} - A_k^* e^{-j(\omega_k (t+\tau) + \phi_k)} \right) dt \right) \\
&= -\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left\{ A_n A_k e^{j(\omega_n + \omega_k)t} e^{j(\phi_n + \phi_k)} e^{j\omega_k \tau} - A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} - \right. \\
&\quad \left. A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} + A_n^* A_k^* e^{-j(\omega_n + \omega_k)t} e^{-j(\phi_n + \phi_k)} e^{-j\omega_k \tau} \right\} dt \\
&= -\frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left(-A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} - A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} \right) dt \\
&= \frac{E_0^2}{4} \left(\sum_{k=1}^M |A_k|^2 e^{-j\omega_k \tau} + \sum_{k=1}^M |A_k|^2 e^{j\omega_k \tau} \right) \\
&= \bar{g}_R(\tau)
\end{aligned}$$

$$\text{Logo, } \bar{g}_I(\tau) = \bar{g}_R(\tau) = \bar{g}(\tau) = \frac{1}{2} \bar{R}_c(\tau).$$

A correlação cruzada temporal entre as partes real e imaginária de uma função amostra de $c(t)$ e dada por

$$\begin{aligned} \bar{h}(\tau) &= \left\langle \left(\text{Re}\{c(t)\} \text{Im}\{c(t+\tau)\} \right) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \left(\text{Re}\{c(t)\} \text{Im}\{c(t+\tau)\} \right) dt \right) \quad (\text{B.28}) \\ &= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \frac{E_0^2}{4j} \sum_{n=1}^M \sum_{k=1}^M \left(A_n e^{j(\omega_n t + \phi_n)} + A_n^* e^{-j(\omega_n t + \phi_n)} \right) \left(A_k e^{j(\omega_k(t+\tau) + \phi_k)} - A_k^* e^{-j(\omega_k(t+\tau) + \phi_k)} \right) dt \right) \\ &= \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left\{ A_n A_k e^{j(\omega_n + \omega_k)t} e^{j(\phi_n + \phi_k)} e^{j\omega_k \tau} - A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} + \right. \\ &\quad \left. A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} - A_n^* A_k^* e^{-j(\omega_n + \omega_k)t} e^{-j(\phi_n + \phi_k)} e^{-j\omega_k \tau} \right\} dt \\ &= \frac{E_0^2}{4} \sum_{n=1}^M \sum_{k=1}^M \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \left(-A_n A_k^* e^{j(\omega_n - \omega_k)t} e^{j(\phi_n - \phi_k)} e^{-j\omega_k \tau} + A_n^* A_k e^{j(\omega_k - \omega_n)t} e^{j(\phi_k - \phi_n)} e^{j\omega_k \tau} \right) dt \\ &= \frac{E_0^2}{4} \left(-\sum_{k=1}^M |A_n|^2 e^{-j\omega_k \tau} + \sum_{k=1}^M |A_n|^2 e^{j\omega_k \tau} \right) = 0 \end{aligned}$$

Finalmente, observe que

- $\langle c(t) \rangle = E\{c(t)\}$
 - $\bar{R}_c(\tau) = R_c(\tau)$
 - $\bar{g}(\tau) = g(\tau)$
 - $\bar{h}(\tau) = h(\tau)$
- (B.29)

ou seja, as médias estatísticas e temporais são iguais. Conseqüentemente o modelo de propagação por espalhamento de Clarke é ergódico tanto em média quanto em funções de correlação (veja (A.7)).

B.2 CÁLCULO DAS PROPRIEDADES ESTATÍSTICAS DO MODELO DE DENT

B.2.1 MÉDIAS ESTATÍSTICAS

Para os cálculos que seguem, assume-se que ϕ_n é uma RV uniformemente distribuída de 0 a 2π e independente para qualquer n .

A esperança de $T_k(t)$ em (3.59) é dada por

$$E\{T_k(t)\} = \sqrt{\frac{2}{M_0}} \sum_{n=1}^{M_0} b_k^{M_0} [n] e^{j\beta_n} E\{\cos(\omega_n t + \phi_n)\} = 0 \quad (\text{B.30})$$

A função de autocorrelação de $T_k(t)$ é dada por

$$\begin{aligned} R_T(t_1, t_2) &= E\{T_k(t_1)T_k^*(t_2)\} \\ &= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0} [n] b_k^{M_0} [m] e^{j\beta_n} e^{-j\beta_m} E\{\cos(\omega_n t_1 + \phi_n) \cos(\omega_m t_2 + \phi_m)\} \end{aligned} \quad (\text{B.31})$$

Para $n \neq m$, a esperança na equação acima vem a ser

$$E\{\cos(\omega_n t_1 + \phi_n)\} E\{\cos(\omega_m t_2 + \phi_m)\} = 0 \quad (\text{B.32})$$

Já para $n = m$, tem-se

$$\begin{aligned} E\{\cos(\omega_n t_1 + \phi_n) \cos(\omega_n t_2 + \phi_n)\} &= E\left\{\frac{(e^{j(\omega_n t_1 + \phi_n)} + e^{-j(\omega_n t_1 + \phi_n)})(e^{j(\omega_n t_2 + \phi_n)} + e^{-j(\omega_n t_2 + \phi_n)})}{4}\right\} \\ &= \frac{1}{4} (E(e^{-j\omega_n(t_2 - t_1)}) + E(e^{j\omega_n(t_2 - t_1)})) = \frac{e^{-j\omega_n(t_2 - t_1)} + e^{j\omega_n(t_2 - t_1)}}{4} \\ &= \frac{1}{2} \cos(\omega_n(t_2 - t_1)) \end{aligned} \quad (\text{B.33})$$

Voltando à equação inicial, com $\tau = t_2 - t_1$, tem-se

$$\begin{aligned} R_T(\tau) &= \frac{1}{M_0} \sum_{n=1}^{M_0} b_k^{M_0} [n]^2 \cos(\omega_n \tau) \\ &= \frac{1}{M_0} \sum_{n=1}^{M_0} \cos\left(2\pi f_m \tau \cos\frac{2\pi(n-0,5)}{M}\right) \end{aligned} \quad (\text{B.34})$$

A correlação entre as partes real e imaginária de $T_k(t)$ é dada por

$$\begin{aligned}
 h_T(t_1, t_2) &= E \left\{ \text{Re} \{ T_k(t_1) \} \text{Im} \{ T_k(t_2) \} \right\} \\
 &= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0} [n] b_k^{M_0} [m] \cos \beta_n \sin \beta_m E \left\{ \cos(\omega_n t_1 + \phi_n) \cos(\omega_m t_2 + \phi_m) \right\} \\
 &= \frac{1}{M_0} \sum_{n=1}^{M_0} b_k^{M_0} [n]^2 \cos \beta_n \sin \beta_n \cos(\omega_n \tau) \\
 \Rightarrow h_T(\tau) &= \frac{1}{2M_0} \sum_{n=1}^{M_0} \text{sen} \left(\frac{2\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right)
 \end{aligned} \tag{B.35}$$

A autocorrelação da parte real de $T_k(t)$ é dada por

$$\begin{aligned}
 g_{R_T}(t_1, t_2) &= E \left\{ \text{Re} \{ T_k(t_1) \} \text{Re} \{ T_k(t_2) \} \right\} \\
 &= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0} [n] b_k^{M_0} [m] \cos \beta_n \cos \beta_m E \left\{ \cos(\omega_n t_1 + \phi_n) \cos(\omega_m t_2 + \phi_m) \right\} \\
 &= \frac{1}{M_0} \sum_{n=1}^{M_0} \cos^2 \beta_n \cos(\omega_n \tau) \\
 \Rightarrow g_{R_T}(\tau) &= \frac{1}{M_0} \sum_{n=1}^{M_0} \cos^2 \left(\frac{\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right)
 \end{aligned} \tag{B.36}$$

Com procedimento semelhante, tem-se

$$\begin{aligned}
 g_{I_T}(\tau) &= E \left\{ \text{Im} \{ T_k(t_1) \} \text{Im} \{ T_k(t_2) \} \right\} \\
 &= \frac{1}{M_0} \sum_{n=1}^{M_0} \text{sen}^2 \left(\frac{\pi n}{M_0} \right) \cos \left(2\pi f_m \tau \cos \frac{2\pi(n-0,5)}{M} \right)
 \end{aligned} \tag{B.37}$$

B.2.2 MÉDIAS TEMPORAIS

O valor médio temporal de $T_k(t)$ é dado por

$$\langle (T_k(t)) \rangle = \sqrt{\frac{2}{M_0}} \sum_{n=1}^{M_0} b_k^{M_0} [n] e^{j\beta_n} \langle \cos(\omega_n t + \phi_n) \rangle = 0 \tag{B.38}$$

A função de autocorrelação temporal de $T_k(t)$ é dada por

$$\begin{aligned}
\bar{R}_T(\tau) &= \left\langle (T_k(t) T_k^*(t+\tau)) \right\rangle \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0}[n] b_k^{M_0}[m] e^{j\beta_n} e^{-j\beta_m} \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \cos(\omega_n t + \phi_n) \cos(\omega_m (t+\tau) + \phi_m) dt \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} b_k^{M_0}[n]^2 \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \frac{\cos(\omega_n (2t+\tau) + 2\phi_n) + \cos(\omega_n \tau)}{2} dt \\
&= \frac{1}{M_0} \sum_{n=1}^{M_0} \cos(\omega_n \tau) = R_T(\tau)
\end{aligned} \tag{B.39}$$

A correlação cruzada temporal entre as partes real e imaginária de uma função amostra é dada por

$$\begin{aligned}
\bar{h}_T(\tau) &= \left\langle (\operatorname{Re}\{T_k(t)\} \operatorname{Im}\{T_k(t+\tau)\}) \right\rangle \tag{B.40} \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0}[n] b_k^{M_0}[m] \cos\beta_n \operatorname{sen}\beta_m \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \cos(\omega_n t + \phi_n) \cos(\omega_m (t+\tau) + \phi_m) dt \\
&= \frac{1}{2M_0} \sum_{n=1}^{M_0} \operatorname{sen}(2\beta_n) \cos(\omega_n \tau) = h_T(\tau)
\end{aligned}$$

A função de autocorrelação temporal da parte real de uma função amostra de $T_k(t)$ é dada por

$$\begin{aligned}
\bar{g}_{R_T}(\tau) &= \left\langle (\operatorname{Re}\{T_k(t)\} \operatorname{Re}\{T_k(t+\tau)\}) \right\rangle \tag{B.41} \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0}[n] b_k^{M_0}[m] \cos\beta_n \cos\beta_m \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \cos(\omega_n t + \phi_n) \cos(\omega_m (t+\tau) + \phi_m) dt \\
&= \frac{1}{M_0} \sum_{n=1}^{M_0} \cos^2\beta_n \cos(\omega_n \tau) = g_{R_T}(\tau)
\end{aligned}$$

De forma semelhante

$$\bar{g}_{I_T}(\tau) = \frac{1}{M_0} \sum_{n=1}^{M_0} \operatorname{sen}^2\beta_n \cos(\omega_n \tau) = g_{I_T}(\tau) \tag{B.42}$$

A covariância entre duas funções amostras desse modelo é dada por

$$\begin{aligned}
\bar{C}_{T_k T_z}(\tau) &= \langle (T_k(t) T_z^*(t+\tau)) \rangle - \langle (T_k(t)) \rangle \langle (T_z^*(t+\tau)) \rangle \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} \sum_{m=1}^{M_0} b_k^{M_0}[n] b_z^{M_0}[m] e^{j\beta_n} e^{-j\beta_m} \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \cos(\omega_n t + \phi_{k,n}) \cos(\omega_m(t+\tau) + \phi_{z,m}) dt \\
&= \frac{2}{M_0} \sum_{n=1}^{M_0} b_k^{M_0}[n] b_z^{M_0}[n] \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \frac{\cos(\omega_n(2t+\tau) + \phi_{k,n} + \phi_{z,n}) + \cos(\omega_n \tau + \phi_{z,n} - \phi_{k,n})}{2} dt \\
&= \frac{1}{M_0} \sum_{n=1}^{M_0} b_k^{M_0}[n] b_z^{M_0}[n] \cos(\omega_n \tau + \phi_{z,n} - \phi_{k,n})
\end{aligned} \tag{B.43}$$

B.3 CÁLCULO DAS MÉDIAS TEMPORAIS PARA O MODELO JAKES

MODIFICADO

O valor médio temporal de (3.65) pode ser calculado por

$$\begin{aligned}
\langle (x(t)) \rangle &= \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \sqrt{\frac{2}{M}} \sum_{n=1}^M e^{j\psi_n} \cos(\omega_n t \cos \alpha_n + \phi) dt \right) \\
&= \sqrt{\frac{2}{M}} \sum_{n=1}^M e^{j\psi_n} \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \cos(\omega_n t \cos \alpha_n + \phi) dt \right) = 0 \\
\Rightarrow \langle (x_R(t)) \rangle &= 0 = \langle (x_I(t)) \rangle
\end{aligned} \tag{B.44}$$

A função de autocorrelação temporal das partes real e imaginária é dada por

$$\begin{aligned}
\tilde{g}_R(\tau) &= \langle (x_R(t) x_R(t+\tau)) \rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T x_R(t) x_R(t+\tau) dt \right) \\
&= \frac{2}{M} \sum_{n=1}^M \sum_{z=1}^M \cos(\psi_n) \cos(\psi_z) \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \cos(\omega_n t \cos \alpha_n + \phi) \cos(\omega_m(t+\tau) \cos \alpha_z + \phi) dt \right) \\
&= \frac{2}{M} \sum_{n=1}^M \sum_{z=1}^M \cos(\psi_n) \cos(\psi_z) \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \cos(\omega_m t \cos \alpha_n + \phi) \cos(\omega_m t \cos \alpha_z + \phi) \cos(\omega_m \tau \cos \alpha_z) \right. \\
&\quad \left. - \frac{1}{T} \int_0^T \cos(\omega_m t \cos \alpha_n + \phi) \sin(\omega_m t \cos \alpha_z + \phi) \sin(\omega_m \tau \cos \alpha_z) \right) \\
&= \frac{1}{M} \sum_{n=1}^M \cos^2(\psi_n) \cos(\omega_n \tau \cos \alpha_n)
\end{aligned} \tag{B.45}$$

$$\begin{aligned}
\tilde{g}_1(\tau) &= \left\langle (x_1(t)x_1(t+\tau)) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T x_1(t)x_1(t+\tau) dt \right) \quad (\text{B.46}) \\
&= \frac{2}{M} \sum_{n=1}^M \sum_{z=1}^M \text{sen}(\psi_n)\text{sen}(\psi_z) \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \cos(\omega_m t \cos \alpha_n + \phi) \cos(\omega_m (t+\tau) \cos \alpha_z + \phi) dt \right) \\
&= \frac{1}{M} \sum_{n=1}^M \text{sen}^2(\psi_n) \cos(\omega_m \tau \cos \alpha_n)
\end{aligned}$$

onde os símbolos “—” e “~” (sobre o caractere que representa a função) indicam média temporal e valor obtido através de cálculo, respectivamente.

Correlação temporal entre as partes real e imaginária

$$\begin{aligned}
\tilde{h}(\tau) &= \left\langle (x_R(t)x_I(t+\tau)) \right\rangle = \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T x_R(t)x_I(t+\tau) dt \right) \quad (\text{B.47}) \\
&= \frac{2}{M} \sum_{n=1}^M \sum_{z=1}^M \cos(\psi_n)\text{sen}(\psi_z) \lim_{T \rightarrow \infty} \left(\frac{1}{T} \int_0^T \cos(\omega_m t \cos \alpha_n + \phi) \cos(\omega_m (t+\tau) \cos \alpha_z + \phi) dt \right) \\
&= \frac{1}{2M} \sum_{n=1}^M \text{sen}(2\psi_n) \cos(\omega_m \tau \cos \alpha_n)
\end{aligned}$$

Note que

$$\left\langle (x_1(t)x_R(t+\tau)) \right\rangle = \left\langle (x_R(t)x_I(t+\tau)) \right\rangle \quad (\text{B.48})$$

Função de autocorrelação de $x(t)$

$$\begin{aligned}
\tilde{R}_x(\tau) &= \left\langle (x(t)x^*(t+\tau)) \right\rangle \\
&= \left\langle (x_R(t)x_R(t+\tau) - jx_R(t)x_I(t+\tau) + jx_I(t)x_R(t+\tau) + x_I(t)x_I(t+\tau)) \right\rangle \\
&= \tilde{g}_R(\tau) - j\tilde{h}(\tau) + j\tilde{h}(\tau) + \tilde{g}_I(\tau) \quad (\text{B.49}) \\
&= \frac{1}{M} \sum_{n=1}^M \cos(\omega_m \tau \cos \alpha_n)
\end{aligned}$$

De (B.49)

$$\left\langle |x(t)|^2 \right\rangle = 1 \quad \Rightarrow \quad \tilde{\sigma}^2 = \frac{1}{2}$$

APÊNDICE C

CÁLCULOS DIVERSOS E PROPRIEDADES

C.1 CÁLCULO DA ESPERANÇA DO PRODUTO ENTRE DUAS SENÓIDES

Seja $\varphi[k] = \{\varphi_0, \varphi_1, \dots, \varphi_k, \dots, \varphi_{N-1}\}$ uma seqüência de variáveis aleatórias independentes e uniformemente distribuídas no intervalo $[0, 2\pi)$. Então, considere o seguinte cálculo

$$\begin{aligned} E\{\cos(\varphi_k + 2\pi kn_1/N)\cos(\varphi_z + 2\pi zn_2/N)\} = \\ \cos(2\pi kn_1/N)\cos(2\pi zn_2/N)E\{\cos\varphi_k \cos\varphi_z\} + \\ -\cos(2\pi kn_1/N)\text{sen}(2\pi zn_2/N)E\{\cos\varphi_k \text{sen}\varphi_z\} + \\ -\text{sen}(2\pi kn_1/N)\cos(2\pi zn_2/N)E\{\text{sen}\varphi_k \cos\varphi_z\} + \\ +\text{sen}(2\pi kn_1/N)\text{sen}(2\pi zn_2/N)E\{\text{sen}\varphi_k \text{sen}\varphi_z\} \end{aligned}$$

Na equação acima, para $k \neq z$, cada esperança do produto pode ser calculada como o produto das esperanças, resultando em um valor final nulo para a equação. Já para $k = z$, as seguintes esperanças devem ser calculadas

$$E\{\cos\varphi_k \cos\varphi_k\} = E\{\text{sen}\varphi_k \text{sen}\varphi_k\} = \frac{1}{2} \quad \text{e} \quad E\{\cos\varphi_k \text{sen}\varphi_k\} = 0 = E\{\text{sen}\varphi_k \cos\varphi_k\}$$

Aplicando esse resultado na equação inicial, chega-se ao resultado final desejado

$$E\{\cos(\varphi_k + 2\pi kn_1/N)\cos(\varphi_z + 2\pi zn_2/N)\} = \begin{cases} \frac{1}{2}\cos\left(\frac{2\pi k}{N}[n_2 - n_1]\right), & k = z \\ 0, & k \neq z \end{cases} \quad (\text{C.1})$$

Realizando procedimento semelhante pode-se obter

$$E\left\{\sin\left(\varphi_k + \frac{2\pi k n_1}{N}\right)\sin\left(\varphi_z + \frac{2\pi z n_2}{N}\right)\right\} = \begin{cases} \frac{1}{2}\cos\left(\frac{2\pi k}{N}[n_2 - n_1]\right), & k = z \\ 0, & k \neq z \end{cases} \quad (\text{C.2})$$

e

$$E\left\{\cos\left(\varphi_k + \frac{2\pi k n_1}{N}\right)\sin\left(\varphi_z + \frac{2\pi z n_2}{N}\right)\right\} = \begin{cases} \frac{1}{2}\sin\left(\frac{2\pi k}{N}[n_2 - n_1]\right), & k = z \\ 0, & k \neq z \end{cases} \quad (\text{C.3})$$

C.2 RELAÇÃO ENTRE ESPECTRO DE SINAL CONTÍNUO E DE SINAL AMOSTRADO

Seja $x(t)$ um sinal contínuo no tempo e limitado em frequência com largura de banda B , conforme ilustrado na Figura C.1. Uma versão amostrada de $x(t)$, pode ser obtida pelo produto entre $x(t)$ e um trem de impulsos $s(t)$ [17]

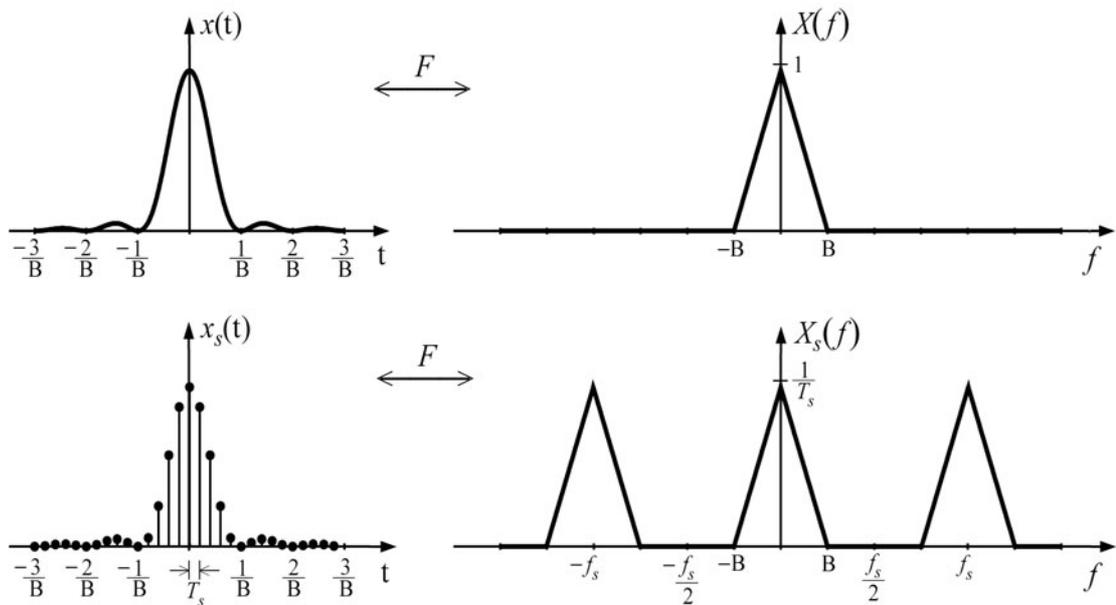


Figura C.1: Amostragem de um sinal limitado em banda e sua transformada de Fourier.

$$x_s(t) = x(t)s(t) \quad (\text{C.4})$$

onde $s(t)$ e sua transformada de Fourier são dados por

$$s(t) = \sum_{n=-\infty}^{\infty} \delta(t - nT_s) \quad \stackrel{F}{\Leftrightarrow} \quad S(f) = \frac{1}{T_s} \sum_{n=-\infty}^{\infty} \delta(f - nf_s) \quad (\text{C.5})$$

onde $f_s = 1/T_s$ é a frequência de amostragem de $x_s(t)$.

A transformada de Fourier $X_s(f)$ da versão amostrada do sinal $x_s(t)$ pode ser escrita utilizando e (C.4) e (C.5)

$$X_s(f) = X(f) * S(f) = \frac{1}{T_s} \sum_{k=-\infty}^{\infty} X(f - kf_s) \quad (\text{C.6})$$

onde o símbolo $*$ indica a operação convolução.

A equação mostra que na ausência de *aliasing* o espectro do sinal amostrado é composto por réplicas do espectro do sinal contínuo repetidas periodicamente a cada intervalo F_s , conforme ilustra a Figura C.1. Segue da equação , que a relação entre $X_s(f)$ e $X(f)$ para valores de frequência dentro da banda do sinal é dada por

$$X_s(f) = \frac{1}{T_s} X(f), \quad |f| \leq \frac{f_s}{2} \quad (\text{C.7})$$

admitindo $f_s \geq 2B$.

APÊNDICE D

PROCEDIMENTOS E FUNÇÕES EM LINGUAGEM

MATLAB[®]

```
function [ct] = jakes_flat_original(b, fm, Ts, M, No)
% -----
% [ct] = jakes_flat_original(b, fm, Ts, M, No);
% -----
% Jakes' Fading Model
% Faithful reproduction of the model suggested by Jakes.
% by Vanderlei A. Silva in 07/11/2003
% -----
% b = power of multipath component (scalar);
% fm = maximum Doppler shift;
% Ts = sampling period;
% M = number of samples;
% No = number of oscillators (Default is 16);
% ct = vector of transmission coefficients
% -----
if nargin == 4
    No = 16; % number of oscillators
end
disp(sprintf('Numero de osciladores = %0.f ', No));
n = 1:No;
Bn = pi*n./(No);
an = 2*pi*n./(4*No+2); % arrival angles
%an = 2*pi*n./(No); % arrival angles
wn = 2*pi*fm*cos(an); % Doppler shift
t = 0:Ts:(M-1)*Ts; % time
ct = zeros(1, M);
for ctn = 1:No
    Fk(ctn,:) = 2*(cos(wn(ctn)*t).*exp(i*Bn(ctn)));
end
ct = sum(Fk, 1) + sqrt(2)*cos(2*pi*fm*t);
ct = sqrt(b./mean(abs(ct).^2)).*ct;
disp(sprintf('Nse jakes_flat_original = %0.f', fm*Ts*M));
```

```
function [afd_nr] = afd_nr(ct, R, Ts)
```

```
% -----
```

```

% [afd,nr] = afd_nr(ct,R,Ts)
% -----
% Calcula a duração media dos desvanecimentos afd
% e a taxa de cruzamento de nível (do nível R) nr;
% Entrada:
%   ct = vetor de coeficientes de desvanecimentos
%   R = vetor de níveis do sinal em dB
%   Ts = período de amostragem
% Saída
%   afd = duração media dos desvanecimentos
%   nr = taxa de cruzamento de nível
R = 10.^(R./20);
M = size(ct,2);
ct = abs(ct);
for ctr = 1:size(R,2)
    aux_ct_real = zeros(1,M);
    idx = find(ct < R(ctr));
    afd(ctr) = size(idx,2)*Ts;
    aux_ct(idx) = 1;
    aux_ct_auxiliar = aux_ct_real == 0;
    n_cruzam = sum(aux_ct_real.*wshift(1,aux_ct_auxiliar,1));
    afd(ctr) = afd(ctr)/n_cruzam;
    nr(ctr) = n_cruzam/(Ts*M);
    clear idx aux_ct_real aux_ct_auxiliar
end

```

```

function [cn] = mpath_sim_f2(b,fm,Ts,N)
% *****
% by Vanderlei A. Silva, 15/12/2003 - versão final e correta para Relatório 2 da Fapesp
% *****
% b = valor médio quadrático da componente multipercurso (MPC).
%   O tamanho de b determina quantas MPCs serão geradas.
% fm = máximo deslocamento Doppler.
% Ts = período de amostragem.
% N = numero de amostras.
% *****
if sum(factor(N) ~= 2) == 0 % se for potencia de dois
    Nt = M,
else
    Nt = ceil(N/1e4);
    % -----
    % *** testa qual o fator primo máximo e impõe o 13 ***
    % -----
    fator_max = max(factor(Nt));
    while fator_max > 13
        Nt = Nt + 1;
    end
end

```

```

        fator_max = max(factor(Nt));
    end
    Nt = Nt * 1e4;
    if 2^(ceil(log2(N))) < Nt
        Nt = 2^(ceil(log2(N)));
    end
    Mt,
end
% -----
Tf = 1/(Ts*Nt);
K = floor(fm/Tf);
k = 1:K-1;
S = zeros(1,K);
S(1:K-1) = sqrt(Nt/Ts * (1./(pi*fm*sqrt(1 - (k*Tf./fm).^2))));
S(K) = sqrt(Nt/Ts * (1/Tf*(0.5-1/pi*asin((K-1)*Tf/fm))) );
Sinv = fliplr(S);
nul = zeros(1,Nt-2*K-1);
cn = zeros(size(b,2),N);
for m = 1:size(b,2)
    %disp(sprintf('\n gerando mpc numero %.0f',m))
    fi(m,:) = 2*pi*rand(1,K);
    finv(m,:) = 2*pi*rand(1,K);
    preal = [0,S.*cos(fi(m,:)),nul,Sinv.*cos(finv(m,:))];
    pimag = [0,S.*sin(fi(m,:)),nul,Sinv.*sin(finv(m,:))];
    rs = ifft([preal + j*pimag],Nt);
    msv = mean(abs(rs(1:N)).^2);
    cn(m,:) = sqrt(b(m)/msv)*rs(1:N);
end

function [cn,teta,un] = mpath_sim_zheng2003(b,fm,Ts,M,N)
% -----
% [cn] = mpath_sim_zheng2003(b,fm,Ts,M);
% Implementação do Modelo Sugerido no Paper:
% "Simulation Models With Correct Statistical Properties for
% Rayleigh Fading Channels".
% Yahong Rosa Zheng and Chengshan Xiao.
% IEEE Trans. Comm. vol 51, No 6, June 2003.
% -----
% By Vanderlei A. Silva, 06 de Janeiro de 2004.
% -----
if nargin == 4
    N = 32; % default number of oscillators
end
% -----
% clear all; clc; b = 1; N = 8; M = 100e3; fm = 100; Ts = 0.025/fm;
n_mpc = size(b,2);

```

```

t = 0:Ts:(M-1)*Ts;
teta = unifrnd(-pi,pi,1,n_mpc);
fi = unifrnd(-pi,pi,1,n_mpc);
un = unifrnd(-pi,pi,n_mpc,N);
for ct_mpc = 1:n_mpc
    soma_r = 0;
    soma_i = 0;
    for ct_n = 1:N
        alfa_n = ( 2*pi*ct_n - pi + teta(ct_mpc) )/(4*N);
        soma_r = soma_r + cos(un(ct_mpc,ct_n)) .*cos( 2*pi*fm*t*cos(alfa_n) + fi(ct_mpc) );
        soma_i = soma_i + sin(un(ct_mpc,ct_n)) .*cos( 2*pi*fm*t*cos(alfa_n) + fi(ct_mpc) );
    end
    Xr(ct_mpc,:) = soma_r*sqrt(2/N);
    Xi(ct_mpc,:) = soma_i*sqrt(2/N);
    cn(ct_mpc,:) = Xr(ct_mpc,:) + i*Xi(ct_mpc,:);
% disp(sprintf('Nse mpath_sim_zheng2003 = %.0f',2*fm*Ts*M));
end

```

```

function [cn] = mpath_sim_young(b,fm,Ts,M)
% *****
% Versão modificada do algoritmo de Smith sugerido por Young em:
% "The Generation of Correlated Rayleigh Random Variates by Inverse
% Discrete Fourier Transform". IEEE Trans. Comm., vol 48, No 7, July 2000
% *****
% by Vanderlei A. Silva, 01/04/2004
% *****
% clear all; clc; b = 1; fm = 7.53546; Ts = 5000e-6; M = 200e3;
% disp(sprintf('mapth_sim Relatorio 2 Fapesp'))
% clear all; clc; b = 1; fm = 7.53546;
% Ts = 1000e-6; M = 50e3;
Mt = ceil(M/1e4)*1e4;
Tf = 1/(Ts*Mt);
fm = fm*Ts;
km = floor(fm*Mt);
k = 1:km-1;
Fmp(1:km-1) = sqrt(1./(2*sqrt(1-(k./(Mt*fm)).^2)));
Fmp(km) = sqrt(km/2 * (pi/2-atan( (km-1)/(sqrt(2*km-1)) ));
Fmn = fliplr(Fmp);
var_x = 0.5 * Mt^2 / sum([Fmp,Fmn].^2);
nul = zeros(1,Mt-2*km-1);
cn = zeros(size(b,2),M);
for m = 1:size(b,2)
    Akp = randn(1,km)*sqrt(var_x);
    Akn = randn(1,km)*sqrt(var_x);
    Bkp = randn(1,km)*sqrt(var_x);
    Bkn = randn(1,km)*sqrt(var_x);

```

```

preal = [0,Fmp.*Akp,nul,Fmn.*Akn];
pimag = [0,Fmp.*Bkp,nul,Fmn.*Akn];
rs = ifft([preal - j*pimag],Mt);
msv = mean(abs(rs(1:M)).^2);
cn(m,:) = sqrt(b(m)/msv)*rs(1:M);
end

```

```

function [cn] = mpath_sim_correl(b,fm,Ts,M,Ro)
% *****
% [cn] = mpath_sim_correl(b,fm,Ts,M,Ro)
% *****
% by Vanderlei A. Silva, 28/05/2004 - versão final e correta
% *****
% b = vetor de potencias das componentes multipercursos;
% fm = máximo deslocamento Doppler;
% Ts = período de amostragem;
% M = numero de amostras;
% Ro = matriz de correlação;
% *****
% *****
Mt = ceil(M/1e4)*1e4;
Tf = 1/(Ts*Mt);
K = floor(fm/Tf);
k = 1:K-1;
S = zeros(1,K);
S(1:K-1) = sqrt(Mt/Ts * (1./(pi*fm*sqrt(1 - (k*Tf./fm).^2))));
S(K) = sqrt(Mt/Ts * (1/Tf*(0.5-1/pi*asin((K-1)*Tf/fm)))) ;
Sinv = fliplr(S);
nul = zeros(1,Mt-2*K-1);
cn = zeros(size(b,2),M);
for m = 1:size(b,2)
    fi(m,:) = 2*pi*rand(1,K);
    finv(m,:) = 2*pi*rand(1,K);
    preal = [0,S.*cos(fi(m,:)),nul,Sinv.*cos(finv(m,:))];
    pimag = [0,S.*sin(fi(m,:)),nul,Sinv.*sin(finv(m,:))];
    rs = ifft([preal + j*pimag],Mt);
    msv = mean(abs(rs(1:M)).^2);
    cn(m,:) = sqrt(1/msv)*rs(1:M);
end
if nargin == 5
    [V,Z] = eig(Ro);
    A = V*sqrt(Z);
    cn = A*cn;
    vmq = [mean((abs(cn).^2),2)]';
else
    vmq = ones(1,size(b,2));
end

```

```

end
for ctn = 1:size(cn,1)
    cn(ctn,:) = cn(ctn,:)*sqrt(b(ctn)/vmq(ctn));
end

```

```

function [cn] = mpath_sim_3d_v01(b,fm,Ts,M,Bmax)
% *****
% by Vanderlei A. Silva, 17/06/2004 - versao final e correta
% *****
% b = vetor contendo as potências das MPCs;
% fm = máximo deslocamento Doppler;
% Ts = período de amostragem;
% M = número de amostras;
% Bmax = máximo ângulo de elevação "...EM GRAUS..."
% *****
% clear all; clc; b = 1; fm = 100; Ts = 300e-6; M = 50e3; Bmax = 20;
disp(sprintf('\n Modelo Proposto Adaptado'))
Bmax = Bmax*pi/180;      Mt = ceil(M/1e4)*1e4;
Tf = 1/(Ts*Mt);        f = 0:Tf:fm;
Km = floor(fm/Tf);     Kc = ceil(fm*cos(Bmax)/Tf);
k = 1:Kc-1;           S = zeros(1,Km);
S(1:Kc-1) = 1/(2*pi*fm*sin(Bmax)) * ...
    (pi/2 - asin( (2*cos(Bmax).^2-1-(k*Tf./fm).^2)./(1-(k*Tf./fm).^2) ) );
S(Kc:end) = 1/(2*fm*sin(Bmax)); % 2*sum(S*Tf)
S = sqrt(Mt/Ts * S);      Sinv = fliplr(S);
nul = zeros(1,Mt-2*Km-1); cn = zeros(size(b,2),M);
for m = 1:size(b,2)
    fi = 2*pi*rand(1,Km);
    finv = 2*pi*rand(1,Km);
    preal = [0,S.*cos(fi),nul,Sinv.*cos(finv)];
    pimag = [0,S.*sin(fi),nul,Sinv.*sin(finv)];
    rs = ifft([preal + j*pimag],Mt);
    msv = mean(abs(rs(1:M)).^2),
    cn(m,:) = sqrt(b(m)/msv)*rs(1:M);
end

```

```

function [cn] = mpath_sim_rice(br,fm,Ts,M,K,fi,fo)
% *****
% by Vanderlei A. Silva, 17/06/2004 - versao final e correta
% *****
% br = vetor contendo as potências das MPCs;
% fm = máximo deslocamento Doppler (Hz);
% Ts = período de amostragem (segundos);
% M = número de amostras;

```

```

% K = fator Rice em dB;
% fi = angulo de fase da componente especular (radianos);
% fo = deslocamento Doppler da componente especular (Hz);
% *****
% Para simular mais que uma MPC, a primeira devera ser Rice e as demais Rayleigh.
% Observe esta ordem nas valores medios quadraticos presentes em br.
% *****
K = 10^(K/10);
A = sqrt(K.*(br./(1+K)));
if length(br) > 1
    b = [br(1)/(1+K),br(2:end)];
else
    b = br/(1+K);
end
Mt = ceil(M/1e4)*1e4;
Tf = 1/(Ts*Mt);
Km = floor(fm/Tf);
k = 1:Km-1;
S = zeros(1,Km);
S(1:Km-1) = sqrt(Mt/Ts * (1./(pi*fm*sqrt(1 - (k*Tf./fm).^2))));
S(Km) = sqrt(Mt/Ts * (1/Tf*(0.5-1/pi*asin((Km-1)*Tf/fm)))) ;
Sinv = fliplr(S);
nul = zeros(1,Mt-2*Km-1);
cn = zeros(size(b,2),M);
for m = 1:size(b,2)
    fase(m,:) = 2*pi*rand(1,Km);
    faseinv(m,:) = 2*pi*rand(1,Km);
    preal = [0,S.*cos(fase(m,:)),nul,Sinv.*cos(faseinv(m,:))];
    pimag = [0,S.*sin(fase(m,:)),nul,Sinv.*sin(faseinv(m,:))];
    rs = ifft([preal + j*pimag],Mt);
    msv = mean(abs(rs(1:M)).^2);
    cn(m,:) = sqrt(b(m)/msv)*rs(1:M);
end
if nargin == 7
    n = 0:M-1;
    wo = 2*pi*fo;
    T = A*exp(sqrt(-1).*wo*n*Ts + fi);
else
    T = A*exp(fi);
end
cn(1,:) = cn(1,:) + T;

```

ANEXO A

ARQUIVO DE AJUDA DO MATLAB[®], VERSÃO 6.0

MATLAB Function Reference

fft: Discrete Fourier transform

Syntax

- $Y = \text{fft}(X)$
- $Y = \text{fft}(X,n)$
- $Y = \text{fft}(X,[],\text{dim})$
- $Y = \text{fft}(X,n,\text{dim})$

Definition

The functions $X = \text{fft}(x)$ and $x = \text{ifft}(X)$ implement the transform and inverse transform pair given for vectors of length N by:

$$X(k) = \sum_{j=1}^N x(j) \omega_N^{(j-1)(k-1)}$$
$$x(j) = (1/N) \sum_{k=1}^N X(k) \omega_N^{-(j-1)(k-1)}$$

where

$$\omega_N = e^{(-2\pi i)/N}$$

is an N th root of unity.

Description

$Y = \text{fft}(X)$ returns the discrete Fourier transform (DFT) of vector X , computed with a fast Fourier transform (FFT) algorithm.

If X is a matrix, fft returns the Fourier transform of each column of the matrix.

If X is a multidimensional array, fft operates on the first nonsingleton dimension.

$Y = \text{fft}(X,n)$ returns the n -point DFT. If the length of X is less than n , X is padded with trailing zeros to length n . If the length of X is greater than n , the sequence X is truncated. When X is a matrix, the length of the columns are adjusted in the same manner.

$Y = \text{fft}(X,[],\text{dim})$ and $Y = \text{fft}(X,n,\text{dim})$ applies the FFT operation across the dimension dim .

Algorithm

The FFT functions (`fft`, `fft2`, `fftn`, `ifft`, `ifft2`, `ifftn`) are based on a library called FFTW [3],[4]. To compute an N -point DFT when N is composite (that is, when $N = N_1 N_2$), the FFTW library decomposes the problem using the Cooley-Tukey algorithm [1], which first computes N_1 transforms of size N_2 , and then computes N_2 transforms of size N_1 . The decomposition is applied recursively to both the N_1 - and N_2 -point DFTs until the problem can be solved using one of several machine-generated fixed-size "codelets." The codelets in turn use several algorithms in combination, including a variation of Cooley-Tukey [5], a prime factor algorithm [6], and a split-radix algorithm [2]. The particular factorization of N is chosen heuristically.

When N is a prime number, the FFTW library first decomposes an N -point problem into three $(N - 1)$ -point problems using Rader's algorithm [7]. It then uses the Cooley-Tukey decomposition described above to compute the $(N - 1)$ -point DFTs.

For most N , real-input DFTs require roughly half the computation time of complex-input DFTs. However, when N has large prime factors, there is little or no speed difference.

The execution time for `fft` depends on the length of the transform. It is fastest for powers of two. It is almost as fast for lengths that have only small prime factors. It is typically several times slower for lengths that are prime or which have large prime factors.

References

[1] Cooley, J. W. and J. W. Tukey, "An Algorithm for the Machine Computation of the Complex Fourier Series," *Mathematics of Computation*, Vol. 19, April 1965, pp. 297-301.

[2] Duhamel, P. and M. Vetterli, "Fast Fourier Transforms: A Tutorial Review and a State of the Art," *Signal Processing*, Vol. 19, April 1990, pp. 259-299.

[3] FFTW (<http://www.fftw.org>)

[4] Frigo, M. and S. G. Johnson, "FFTW: An Adaptive Software Architecture for the FFT," *Proceedings of the International Conference on Acoustics, Speech, and Signal Processing*, Vol. 3, 1998, pp. 1381-1384.

[5] Oppenheim, A. V. and R. W. Schaffer, *Discrete-Time Signal Processing*, Prentice-Hall, 1989, p. 611.

[6] Oppenheim, A. V. and R. W. Schaffer, *Discrete-Time Signal Processing*, Prentice-Hall, 1989, p. 619.

[7] Rader, C. M., "Discrete Fourier Transforms when the Number of Data Samples Is Prime," *Proceedings of the IEEE*, Vol. 56, June 1968, pp. 1107-1108.

ANEXO B

ARTIGO PUBLICADO NO “*2004 IEEE INTERNATIONAL SYMPOSIUM ON SPREAD SPECTRUM TECHNIQUES AND APPLICATIONS*”