UNIVERSIDADE FEDERAL DO PARANÁ

CLAUDIO BASTOS DA SILVA



CLAUDIO BASTOS DA SILVA

UMA ABORDAGEM BAYESIANA GENERALIZADA PARA ANÁLISE DO DESVANECIMENTO DO CANAL DE COMUNICAÇÃO

Tese apresentada ao curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Prof. Horácio Tertuliano Filho – Ph.D

CURITIBA 2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP) UNIVERSIDADE FEDERAL DO PARANÁ SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Silva, Claudio Bastos da

Uma abordagem bayesiana generalizada para análise do desvanecimento do canal de comunicação / Claudio Bastos da Silva. — Curitiba, 2025.

1 recurso on-line: PDF.

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica.

Orientador: Horácio Tertuliano dos Santos Filho

Sistemas de transmissão de dados. 2. Taxa de erro de bit. 3.
 Desvanecimento – Transmissores e transmissão - Tecnologia 5G. 4.
 Modelamento bayesiano. I. Universidade Federal do Parana. II. Programa de
Pós-Graduação em Engenharia Elétrica. III. Santos Filho, Horácio Tertuliano
dos. IV. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÔ-REITORIA DE PÔS-GRADUAÇÃO
PROGRAMA DE PÔS-GRADUAÇÃO ENGENHARIA
ELÉTRICA - 40001016043P4

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de CLAUDIO BASTOS DA SILVA, intituiada: Uma abordagem bayesiana generalizada para analise do desvanecimento do canal de comunicação., sob orientação do Prof. Dr. HORACIO TERTULIANO DOS SANTOS FILHO, que após terem inquírido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita á homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pieno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curtiba. 02 de Abril de 2025.

Assinatura Eletrónica 08/04/2025 16:10:16.0 HORACIO TERTULIANO DOS SANTOS FILHO Presidente da Banca Examinadora

Assinatura Eletrônica 08/04/2025 17:02:39.0 CÉSAR AUGUSTO DARTORA Avallador Interno (UNIVERSIDADE FEDERAL DO PARANÁ) Assinatura Eletrônica 09/04/2025 09:37:27.0 PAULO CESAR PELLANDA Availador Externo (INSTITUTO MILITAR DE ENGENHARIA, DEPARTAMENTO DE ENGENHARIA ELÉTRICA - RJ)

Assinatura Eletrônica
08/04/2025 16:22:26.0

MARCOS LAJOVIC CARNEIRO

Availador Externo (PONTIFICIA UNIVERSIDADE CATÓLICA DE GOIAS)

DEDICATÓRIA

- João Bastos da Silva †
- Pedro Bastos da Silva †
- Eliseu Bastos da Silva†

AGRADECIMENTO

A Lidiane (\mathcal{L}) Furlani, dileta companheira de todas as horas, cujo amor e dedicação iluminaram cada passo desta jornada. Sem teu apoio incansável, tua paciência serena nos momentos de turbulência e teu incentivo firme diante das incertezas, esta conquista não teria sido possível. Em cada página lida, em cada linha escrita esteve comigo sua presença silenciosa, mas essencial, como bússola e porto seguro. Tenha sempre toda minha reverência e amor.

Ao Prof. Horácio Tertuliano pela orientação sábia, pela paciência generosa e pelo rigor intelectual que nortearam esta pesquisa. Sua expertise e compromisso moldaram este trabalho e ampliaram meus horizontes acadêmicos. Cada crítica, cada sugestão e cada estímulo foram fundamentais para a conclusão desta jornada. Por isso, minha eterna gratidão.

Aos colegas do Laboratório de Telecomunicações, pela parceria enriquecedora, pelas discussões estimulantes e pelo ambiente de colaboração que fortaleceram esta pesquisa. Seja no compartilhamento de ideias, na resolução conjunta de desafios ou no simples apoio cotidiano, cada um de vocês contribuiu, de alguma forma, para que este trabalho alcançasse seu propósito. Que o conhecimento aqui construído seja o testemunho de nosso esforço coletivo.

Uma pessoa racional deve acreditar que Deus existe. Porque você tem tudo a ganhar se estiver certo e nada a perder se estiver errado.

Blaise Pascal - Pensées.

RESUMO

Este trabalho propõe o desenvolvimento de um modelo estatístico computacional baseado em inferência bayesiana para caracterizar o fenômeno de desvanecimento (fading) em canais de comunicação, com ênfase no espectro de ondas milimétricas (mmW, 30-300 GHz), utilizado em sistemas de quinta geração (5G). O fading é um fenômeno estocástico que afeta significativamente a qualidade da transmissão e recepção de sinais. Modelos estatísticos clássicos, como os de Rayleigh, Rice e Nakagami, utilizados nas faixas de frequência em uso atual, apresentam limitações técnicas e matemáticas na representação do comportamento do canal no espectro mmW, onde o espalhamento do sinal é reduzido ou inexistente e a propagação tende a um sinal da óptica geométrica. A abordagem bayesiana adotada neste estudo permite a incorporação de informações prévias e a atualização contínua das estimativas com base em novas observações, oferecendo maior flexibilidade e precisão na modelagem de ambientes altamente variáveis. O avanço computacional recente viabiliza a aplicação prática dessa abordagem, inclusive em algoritmos de inteligência artificial e aprendizado de máquina, permitindo a integração com tecnologias emergentes. Como resultado, espera-se obter um modelo mais aderente às características físicas do canal mmW, com maior capacidade preditiva e aplicabilidade prática. O modelo proposto visa também servir como ferramenta de simulação e suporte à análise, projeto e otimização de enlaces, contribuindo para o aumento da confiabilidade, eficiência espectral e robustez dos modernos sistemas de comunicação sem fio.

Palavras-chave: Average fade duration (AFD); Bit error rate (BER); Fading em 5G; Level crossing rate (LCR); Modelamento bayesiano.

ABSTRACT

This study develops a statistical model based on Bayesian inference to describe fading in communication channels, focusing on the millimeter-wave (mmW) spectrum used in 5G communication systems. Fading is a stochastic effect critical in signal degradation during transmission and reception. Classical statistical models, such as Rayleigh, Rice, and Nakagami, commonly applied to current frequency bands, present technical and mathematical limitations when representing channel behavior in the mmW spectrum, where signal scattering is minimal or absent, and propagation tends to resemble geometric optics. The Bayesian approach adopted in this study enables the incorporation of prior information and continuous updating of estimates based on new observations, offering greater flexibility and accuracy in modeling highly variable environments. Recent advances in computational power have made the practical application of this approach feasible, including its integration into artificial intelligence and machine learning algorithms, thus enabling compatibility with emerging technologies. As an outcome, the proposed model is expected to better align with the physical characteristics of mmW channels, providing enhanced predictive capability and practical applicability. It also aims to be a simulation tool and a support structure for the analysis, design, and optimization of communication links and to contribute to improving reliability, spectral efficiency, and robustness in modern wireless communication systems.

Keywords: Average fade duration (AFD); Bit error rate (BER); Fading; Level crossing rate (LCR); Bayesian model.

LISTA DE FIGURAS

FIGURA 1 - ATENUAÇÃO DO ESPAÇO LIVRE PARA DIFERENTES	
FREQUÊNCIAS	. 24
FIGURA 2 - PERDAS POR ABSORÇÃO GASOSA	. 25
FIGURA 3 - ATENUAÇÃO CAUSADA POR CHUVAS	. 26
FIGURA 4- DIAGRAMA ESQUEMÁTICO EFEITO DOPPLER	. 29
FIGURA 5 – TEMPERATURA DE RUÍDO DA ANTENA	. 30
FIGURA 6 - DIAGRAMA DE BLOCOS MEDIÇÃO BANDA ESTREITA	. 34
FIGURA 7 - MEDIÇÃO VNA COM VARREDURA DE FREQUÊNCIA	. 35
FIGURA 8 - MEDIÇÃO CORRELAÇÃO DE BANDA LARGA NO DOMÍNIO D	О
TEMPO	. 36
FIGURA 9 - FDP DE RICE PARA DIFERENTES VALORES DE K	. 49
FIGURA 10 - LUXOGRAMA SEQUÊNCIA DE CALCULOS	. 59
FIGURA 11 - COMPORTAMENTO DA DIST GAMA PARA DIVERSOS	
VALORES DE α E θ	. 61
FIGURA 12 - SUPERFICIE DA PDF CONJUNTA fx,y	. 64
FIGURA 13 - COMPORTAMENTO DA DIST \pounds EM FUNÇÃO DOS VALORES	3
DE Y	. 65
FIGURA 14 - FUNÇÃO DISTRIB ACUMULADA (FDA) DISTB \mathcal{L}	. 69
FIGURA 15 - LCR E AFD	. 70
FIGURA 16 - RESPOSTA AO IMPULSO DO CANAL SIMULADO AO LONGO	0
DO TEMPO	. 79
FIGURA 17 - (a) SINAL PURO TRANSMITIDO; (b) SINAL RECEBIDOO CO	M
RUÍDO GAUSSIANO	. 81
FIGURA 18 - PERDA DE BITS. (a) BITS Tx; (b) BITS RECEBIDOS	. 82
FIGURA 19 - DISTRIBUIÇÃO DE RUÍDOS/INTERFERÊNCIAS NO Rx	. 82
FIGURA 20 - ANÁLISE DA DISTRIBUIÇÃO DE Y - AMPLITUDE DOS RUÍDO	OS
	. 83
FIGURA 21 - SOLUÇÃO SIMULADA DA EXPRESSÃO DO LCR	. 84
FIGURA 22 - LCR COMPARADO PARA OS MODELOS	. 85
FIGURA 23 - DENSIDADE DE PROBABILIDADE DO LCR AO LONGO DO	
TEMPO	85

FIGURA 24 - COMPARATIVO TAXA DE CRUZAMENTOS $\mathcal{L}x$ NAKAGAMI x	
RAYLEIGH86	
FIGURA 25 - DISTRIBUIÇÃO ACUMULADA DURAÇÃO DOS FADES 87	
FIGURA 26 - AFD_ COMPARATIVO DISTRIBUIÇÃO ACUMULADA 87	
FIGURA 27 - HEATMAP VAVARIAÇÃO DO THRESHOLD x DURAÇÃO DO	
FADE 88	
FIGURA 28 - COMP ENTRE A BER TEÓRICA E SIMULADA -AWGN- DA	
DISTRIBUIÇÃO £	
FIGURA 29 - COMPARATIVO BER AWGN 89	
FIGURA 30 - BER COM ADIÇÃO DE RUÍDOS	
FIGURA 31 - COMPARATIVO POTÊNCIA DO SINAL RECEBIDO 91	
FIGURA 32 - SINAL SENOIDAL PURO, SINAL RECEBIDO COM RUÍDOS: (a)	
MODELO \mathcal{L} , (b) NAKAGAMI	
FIGURA 33 – RESPOSTA AO IMPULSO UNITÁRIO DO CANAL SIMULADA	
PARA UMA AMOSTRA NO PERÍODO. 93	
FIGURA 34 - SINAL RECONSTRUÍDO: (a) MODELO L, (b) NAKAGAMI 94	
FIGURA 35 - PDFs DA DISTRIBUIÇÃO DE RUÍDOS DOS SINAIS	
RECONSTRUÍDOS96	
FIGURA 36 - SINAL RECONSTRUÍDO PARA O MODELO ${\mathcal L}$ USANDO: (a)	
MÉTODO TRADICIONAL, (b) FILTRO PARTICULADO 99	
FIGURA 37 - POTÊNCIA DOS RUÍDOS COMPARADA	
FIGURA 38 - HISTOGRAMA DA DISTRIBUIÇÃO DE RUÍDOS DO SINAL	
RECONSTRUÍDO	
FIGURA 39 - DENSIDADE ESPECTRAL DE POTÊNCIA DO RUÍDO DO SINAL	
RECONSTRUÍDO (MODELO \mathcal{L})	
FIGURA 40 - DISTRIB COMPARATIVA DA AMPLITUDE DO SINAL MODELO	
£ vs RAYLEIGH	
FIGURA 41 DISPERSÃO COMPARADA DA DISTRIBUIÇÃO DE	
AMPLITUDES	
FIGURA 42 - DISTRIB COMPARATIVA DA AMPLITUDE DO SINAL MODELO	
\mathcal{L} vs NAKAGAMI	
FIGURA 43 - DISPERSÃO COMPARADA DA DISTRIBUIÇÃO DE	
AMPLITUDES	

LISTA DE SÍMBOLOS

variância
média
função de <i>Bessel</i> modificada do primeiro tipo e ordem zero.
fator K de Rice
parâmetro de controle de escala (Nakagami)
parâmetro de forma (Nakagami)
atenuação específica da chuva
_e - atenuação devido a vegetação
ângulo de fase
variação do ângulo de fase
velocidade
comprimento de onda
banda de coerência
espalhamento <i>Doppler</i>
efeito <i>Doppler</i> /frequência <i>Doppler</i>
tempo de coerência
máximo efeito <i>Doppler</i>
energia do ruído
constante de <i>Boltzmann</i>
temperatura ambiente
figura de ruído no receptor
largura da banda do sinal
temperatura efetiva
potência média
período do sinal
máxima tensão ou envoltória da potência
função gama
operador de expectativa
) - probabilidade de A dado B
B) - probabilidade de A interseção com B

desvio padrão

 σ -

- α parâmetro de forma da função Gama
- θ parâmetro de escala da função Gama
- \mathcal{L} distribuição proposta
- Y varável a posteriori da distribuição \mathcal{L}
- T_r limite de amplitude

E[N(t)] - expectativa ou valor esperado do número de cruzamentos do threshold

 $F(X-T_r)$ - função de distribuição acumulada (CDR) avaliada em $X-T_r$

- Φ função de densidade acumulada da distribuição Normal
- *D_i* tempo de duração dos desvanecimentos
- *Q* função de erro complementar da distribuição normal
- E_h energia por bit
- N_0 densidade espectral de potência do ruído
- T_b tempo de duração do *bit*
- erf(x) função de erro
- erfc(x) função complementar de erro
- SNR relação sinal ruído (Signal Noise Ratio)
- h(t) resposta ao impulso
- * operador convolução
- *FFT* transformada rápida de Fourier (*Fast Fourier Transform*)
- IFFT transformada inversa de Fourier
- BER taxa de erros de bit (Bit Error Rate)
- H(f) função de transferência (transformada de *Fourier*)
- X(f) sinal de entrada (transformada de *Fourier*)
- x(t) sinal de entrada transformado no domínio da frequência
- Y(f) sinal de saída no domínio da frequência
- Y(t) sinal de saída no domínio do tempo
- χ conjunto de amostras (filtro particulado)
- $x^{[j]}$ j-ésima partícula (filtro particulado)
- $\omega^{[j]}$ peso associado à j-ésima partícula (filtro particulado)
- PSD densidade espectral de potência (Power Spectral Density)

SUMÁRIO

1 INTRODUÇÃO	. 14
1.1 DEFINIÇÃO DO PROBLEMA	. 14
1.2 O ESTUDO DO FENÔMENO FADING	. 16
1.3 ESTADO DA ARTE	. 18
1.3.1 Objetivos gerais	. 20
1.3.2 Objetivos específicos	. 20
1.3.3 Justificativa	. 20
1.4 ESTRUTURA DO TRABALHO	. 21
2 PROPAGAÇÃO E MEDIÇÃO EM <i>MMW</i>	. 23
2.1 PROPAGAÇÃO	. 23
2.2 PROPAGAÇÃO NO ESPECTRO MMW	. 23
2.3 PERDAS POR GASES ATMOSFÉRICOS	. 24
2.3.1 Desvanecimento causado por chuvas	. 26
2.4 PERDAS DEVIDO A VEGETAÇÃO	. 27
2.4.1 Penetração em obstáculos	. 27
2.4.2 Efeito Doppler	. 28
2.4.3 Ruídos atmosféricos (temperatura de brilho) no espectro mmW	. 30
2.5 MODELOS DE PROPAGAÇÃO USANDO IA (INTELIGENCIA ARTIFICIA	۱L)
E APRENDIZADO DE MÁQUINA	. 31
2.6 O CANAL DE COMUNICAÇÃO	. 33
2.6.1 Medição do canal	. 34
2.6.2 Medição em banda estreita (<i>NB</i>)	. 34
2.6.3 Medição em banda larga (<i>WB</i>)	. 35
2.7 O CANAL DE COMUNICAÇÃO EM MMW	. 37
2.7.1 Modelos estocásticos em mmW	. 37
2.7.2 Modelos híbridos	. 37
2.8 MODELAMENTO DO CANAL MMW	. 38
2.8.1 O canal <i>mmW</i> padrão	. 38
3 CANAL FADING - O MODELO CLÁSSICO	. 42
3.1 O FADING	. 42
3.2 BANDA DE CORÊNCIA	. 43

3.3 ESPALHAMENTO DOPPLER E TEMPO DE COERÊNCIA	43
3.4 FONTES DE RUÍDO NO CANAL DE COMUNICAÇÃO	45
3.4.1 Perdas de propagação	46
3.4.2 Perdas de larga escala ou slow fading.	46
3.4.3 Desvanecimento rápido ou f <i>ast fading</i>	47
3.5 MODELOS DO CANAL FADING	48
3.5.1 O Modelo de Rice	48
3.5.2 O modelo <i>Rayleigh</i>	49
3.5.3 O Modelo Nakagami	50
4 CANAL FADING - O MODELO BAYESIANO	52
4.1 O TEOREMA DE BAYES	52
4.2 O PROCESSO DE OTIMIZAÇÃO ESTATÍSTICA	54
4.3 O ENFOQUE BAYESINO	55
4.3.1 A modelagem <i>bayesiana</i>	56
4.3.2 Inferência bayesiana	57
5 DEMONSTRAÇÕES, SIMULAÇÕES E RESULTADOS	60
5.1 FUNDAMENTAÇÃO	60
5.1.1 Função Gama e Gama incompleta	60
5.1.2 Distribuição Gama	60
5.1.3 Distribuição Normal	61
5.2 APLICAÇÃO DO TEOREMA DE BAYES	62
5.2.1 Análise da normalização da distribuição $\mathcal L$	65
5.2.2 Análise da expressão da FDP	66
5.2.3 Função de Distribuição Acumulada	68
5.2.4 Considerações gerais da análise	69
$5.3~{ m DETERMINA}$ ÇÃO DOS PARÂMETROS ESTATÍSTICOS DO FADING	69
5.3.1 Cálculo do LCR	70
5.3.2 Cálculo do AFD	73
5.4 TAXA BER – BIT ERROR RATE	75
5.4.1 Taxa BER causada pelo ruido gaussiano branco (AWGN)	75
5.5 RESPOSTA DO CANAL AO IMPULSO	78
5.6 SIMULAÇÕES	79
5.6.1 Simulação e demonstração das distribuições.	82
5.6.2 Simulação do LCR (Level Crossing Rate)	83

5.6.3 Simulação do AFD (Average Fade Duration)	86
5.6.4 Simulação da taxa de bits perdidos (BER)	89
5.6.5 O sinal recebido	91
5.6.6 Reconstruindo o sinal	92
5.6.7 Reconstrução usando técnicas avançadas – Bayesianas	97
6 ANÁLISE E DISCUSSÃO DOS RESULTADOS	102
6.1 ANÁLISE COMPARATIVA ENTRE O MODELO ${\mathcal L}$ E O MODELO	
NAKAGAMI	104
6.2 CARACTERÍSTICAS DA ANÁLISE BAYESIANA	105
6.3 POSSÍVEIS VANTAGENS DO MODELO \pounds PROPOSTO	107
6.3.1 Desafios em ambientes urbanos e suburbanos	108
6.3.2 Melhorias esperadas do modelo proposto	108
6.3.3 Melhorias em áreas urbanas	110
6.4 RECONSTRUÇÃO DO SINAL	111
7 CONCLUSÃO E ESTUDOS FUTUROS	113
8 REFERÊNCIAS	115

1 INTRODUÇÃO

Este capítulo descreve a estrutura da tese e fornece uma visão geral da pesquisa realizada. Aborda temas como contextualização do trabalho, justificativa, objetivos, contribuições e definição dos assuntos que serão abordados nos demais capítulos.

1.1 DEFINIÇÃO DO PROBLEMA

A tecnologia 5G pretende revolucionar o comportamento da sociedade como um todo em áreas tão diversas quanto a medicina, indústria, agricultura, comércio, finanças, educação, relacionamentos interpessoais, telecomunicações etc. Serão trazidas soluções inovadoras para problemas existentes e para aqueles que ainda sequer sabemos que são importantes na rotina e no progresso da sociedade. Novos hábitos e alterações comportamentais serão introduzidos ao cotidiano de forma muito mais profunda comparativamente ao que ocorreu por ocasião da chegada do 4G. Como exemplo pode ser citado:

- Medicina Cirurgias remotas em tempo real com robôs remotos conectados em qualquer parte do mundo, Monitoramento contínuo da saúde por meio de sensores vestíveis (wearables) conectados à nuvem.
- Industria (Indústria 4.0) Fábricas autônomas e inteligentes, com máquinas interconectadas tomando decisões em tempo real com base em dados, manutenção preditiva, realidade aumentada para assistência técnica remota e treinamento de funcionários.
- Agricultura Drones agrícolas, sensores em solo e plantação.
- Comércio Lojas sem atendentes nem caixa, experiência de compra com realidade aumentada, entrega com robôs autônomos gerenciados pela rede 5G de baixíssima latência.
- Finanças Pagamentos instantâneos via IoT, cidades inteligentes com cobrança automática de taxas, maior segurança em trasações por reconhecimento facial.

- Educação Salas de aula imersivas com realidade virtual, laboratórios remotos, plataformas de aprendizado adaptativo com IA em nuvem que ajusta conteúdos com base no desempenho do aluno em tempo real.
- Relacionamentos interpessoais Interações em realidade virtual imersiva, tradução simultânea automática em conversas de vídeo, avatares digitais hiperrealistas substituindo ou complementando interações humanas em ambientes virtuais.
- Telecomunicações Chamadas holográficas em tempo real, Cobertura massiva de dispositivos IoT permitindo cidades e casas cada vez mais inteligentes.

Sob o ponto de vista econômico, a implantação do 5G trará enorme dispêndio financeiro às operadoras em relação a infraestrutura, equipamentos e compra de espectro. Sob o ponto de vista tecnológico, imensos desafios já foram enfrentados e superados e diversos outros ainda se encontram em processo evolutivo de desenvolvimento. Conceitos amplamente consolidados como propagação e medição tiveram que ser revisitados, aprimorados e trazidos para a nova realidade de forma a atender o propósito mais elementar do processo de transmissão: entregar no receptor a mensagem transmitida com máxima fidelidade e segurança.

Em telecomunicações, quando um sinal é transmitido para o receptor, vários fatores podem impactar negativamente a propagação e podem levar a um sinal recebido degradado e a erros nas informações recebidas. Os principais fatores que contribuem para isso são atenuação, absorção, distorção de atraso, ruído, multipercurso e, nas comunicações móveis, a presença do efeito Doppler.

A atenuação do sinal se dá principalmente pelo aumento da distância relativa entre transmissor e receptor e das características do meio como, por exemplo, o tipo de relevo, padrão de urbanização, obstáculos, variações climáticas e atmosféricas. O sinal transmitido deve ter potência suficiente para que o receptor possa detectá-lo e ser maior que o nível de ruído para ser recebido sem erros que comprometam sua qualidade. O aumento da atenuação é diretamente proporcional ao aumento da frequência transmitida.

O ruído é uma componente indesejada gerada adicionalmente entre transmissor e receptor, pode ter origem térmica, intermodulação, interferência co-canal ou por fenômenos atmosféricos. Podem ainda ocorrer distorções por atraso, devido a multipercursos originados por reflexões ou espalhamento do sinal que chegam ao

receptor em tempos diferentes e quando há mobilidade relativa entre transmissor e receptor, o chamado efeito *Doppler* (RAO KUMAR (2007).

Com base nestes vários fatores, que ocasionam perdas da qualidade do sinal, se buscará tratar, neste trabalho, aqueles específicos que causam o desvanecimento do canal ou *fading* em comunicações móveis, sendo que os mais importantes são o multipercurso e o efeito *Doppler*. Em *links* ponto-a-ponto *LOS* (*Line-of-Sight*) ou *NLOS* (*Non-Line-of-Sight*) o fenômeno *fading* não tem impacto na mesma intensidade nem é tratado com o mesmo grau de importância que é dado nos *links* móveis, porém não pode, de forma nenhuma, ser negligenciado mesmo ocorrendo esporadicamente.

O fading é, por natureza, um fenômeno aleatório que exige uma abordagem estatística, a qual será desenvolvida ao longo deste trabalho. Serão analisados diversos fatores que contribuem para sua ocorrência, considerando diferentes ambientes com distintos níveis de propensão ao fenômeno. Além disso, será examinada a influência da variação da frequência de operação dos enlaces na formação e no comportamento do fading.

1.2 O ESTUDO DO FENÔMENO FADING

As variações da amplitude do sinal são chamadas de efeito de desvanecimento do canal ou efeito *fading*. Portanto, o desvanecimento é um fenômeno espacial no qual os sinais sofrem variações no tempo devido ao movimento relativo do transmissor ou receptor, devido a multipercursos ou espalhamentos. Assim, é possível falar de variações nos domínios do espaço e do tempo nos campos eletromagnéticos e no domínio da frequência nos links móveis.

As variações no nível do sinal originam-se basicamente de 4 fundamentos:

- 1. A perda de caminho causada por espalhamento, reflexões, absorção, atenuação do espaço livre. As variações no tempo (multipercurso) e fase do sinal ao longo do percurso, são profundas e lentas.
- 2. O desvanecimento causado pela difração do sinal em obstáculos causa variações lentas no domínio do tempo e profundas no domínio do espaço. Este fenômeno é chamado de desvanecimento lento.

- 3. Variação em pequena escala no domínio do espaço e variações rápidas no domínio do tempo devido à interferência das ondas que compõem o sinal na recepção.
- 4. *Fade* plano no caso de respostas com ganho constante e fase linear na largura de banda, que é maior que a largura da banda do sinal transmitido.

O estudo dos mecanismos de modelamento do canal *fading* tiveram início nas décadas de 1950 e 1960, a ideia era aplicá-los sobre comunicações de horizonte, ionosféricas e troposféricas então existentes e que cobriam uma extensa faixa de frequências (de HF até UHF). Apesar dos efeitos do *fading* em comunicações móveis serem significativamente diferentes dos ocorridos em canais ionosféricos ou troposféricos os primeiros modelos são ainda relevantes na caracterização do fenômeno em sistemas digitais de comunicações móveis como, por exemplo, o conceito de Ruído Aditivo Gaussiano Branco (*AWGN*) estatisticamente distribuídos de forma independente (SKLAR 1997).

A indústria de telecomunicações sem fio desenvolveu e implementou uma infraestrutura para prover variados tipos de serviços aos usuários, o projeto, produção e implementação de cada diferente tecnologia implica em altos custos. Para compatibilizar economia e resultados técnicos desejados uma alternativa é simular, por modelamento, um sistema *wireless* real. A vantagem da simulação é que ela permite economia de custos de testes do projeto de implantação ou de expansão daqueles já implantados (CHAVAN et al. 2011).

Segundo (PATZOLD; WANG, CHENG-XIANG; HOGSTAD O. 2009) nos últimos anos está ocorrendo uma significativa pesquisa em relação ao desempenho dos modelos de canais *wireless*. Neste sistema de transmissão o receptor está em movimento relativo ao transmissor e na maioria das vezes sem visada direta, nesta situação o modelo do canal *fading* de *Rayleigh* é usualmente o que de forma mais realista se aproxima das condições reais do canal (NOGA; PALCZYNKA 2010). O termo canal *fading* de *Rayleigh* se refere a distorções multiplicativas H(t) do sinal transmitido $T_x(t)$ resultando como sinal recebido $R_X(t) = H(t).T_x(t) + n(t)$ onde n(t) é o ruído.

Diversos modelos de simulação tem sido propostos para o canal *fading* em comunicações sem fio incluindo variados tipos de modulação, diferentes tipos de canais (*AWGN*, *flat fading*, *fading* seletivo em frequência (*FSF*)), equalização e demodulação inteligentes (*adaptive*) (CHEN 2007) (JIN et al. 2016) onde foram

considerados os efeitos, para os diferentes tipos de canal para dados e imagens bem como a taxa de erros (*BER*) no receptor. Tem-se avaliado, também, o modelo *fading* de *Clarke* o qual considera um número finito de senóides (JIN et al. 2016) e há a proposição de um modelo estatístico de soma de senóides que, em tese, poderia ser um modelo de simulação alternativo ao do canal *fading* de *Rayleigh* (CHAVAN et al. 2011). Ainda, estão sendo propostos modelos que analisam o fenômeno sob o ponto de vista de ambos os receptores móveis usando movimento *Browniano*, visto que na próxima geração 5G os aparelhos terminais poderão estabelecer comunicação direta entre si (BORHANI 2014), na mesma linha há, também, a proposição de um modelo utilizando cadeias de Markov (ABDUL SALAM et al. 2017).

1.3 ESTADO DA ARTE

Nessa faixa do espectro, o sinal tende a ser absorvido por obstáculos como prédios, vegetação, veículos, pessoas. Também, são mais facilmente absorvidos ou atenuados por moléculas de água ou oxigênio no ar. Além disso, o processamento de sinais requer técnicas e equipamentos mais sofisticados e demandam uma quantidade muito maior de estações base, transmissoras e receptoras.

Nas faixas de frequências atualmente em uso em sistemas *wireless* o *fading* pode ser satisfatoriamente modelado por alguns modelos reconhecidamente eficientes, porém cada um tendo alguma limitação inerente.

Modelo Rice: Dado pela Função Densidade de Probabilidade (FDP):

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}} e^{-k} I_0 \left(\frac{p}{\sigma} \sqrt{2k} \right)$$

Sendo p a envoltória da potência, σ o desvio padrão e I_0 é a função de *Bessel* modificada do primeiro tipo e ordem zero. O fator K de Rice é dado por:

$$K = \frac{SINAL\ DIRETO}{MULTIERCURSO} \frac{[POT\hat{E}NCIA]}{[POT\hat{E}NCIA]}$$

O fator K se torna o limitante deste modelo. Na condição de boa visada entre transmissor e receptor (LOS) e na ausência de componentes multipercurso, fator que aumenta com o aumento da frequência de operação do link, $K \to \infty$ o fading de *Rice* assume o formato da FDP delta de *Dirac*.

Na condição de ausência de sinal direto K=0, o termo $e^{-K}=1$ e $I_0(0)=1$.

 Modelo Rayleigh: Se aplica a ambientes onde há grande nível de espalhamento, típico de ambientes urbanos densos e suburbanos. Este modelo é uma derivação do modelo Rice na condição de K = 0. A FDP de Rayleigh é, portanto, dada por:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}}$$

 Modelo Nakagami: A FDP do modelo de Nakagami, baseada na distribuição Gama, é dada por:

$$FDP(p) = \frac{2m^m}{\Gamma(m)\Omega^m} y^{2m-1} e^{-\frac{m}{\Omega}y^2}$$

Onde Ω é o parâmetro de controle de escala $(\Omega>0)$, m é o parâmetro de forma (m>0,5) determina a profundidade do *fading* e a extensão da cauda da distribuição, y é a variável aleatória que representa a amplitude do sinal. Dependendo do valor de m, a distribuição Nakagami assume algumas particularidades; quando m tende ao infinito, o canal tende a um canal estático (LOS). Quando m tende a 1, a distribuição Nakagami-m torna-se a distribuição de Rayleigh, e para os valores de m>1 Nakagami aproxima-se da distribuição de Rice.

O modelo *Nakagami* contorna as limitações do fator *K* do modelo de *Rice*, porém é um modelo desenvolvido sobre as bases da estatística clássica ou frequentista não sendo flexível o suficiente para aplicações em *Machine Learning* ou em algoritmos de inteligência artificial.

O modelo proposto nesta tese é baseado numa distribuição conjunta de probabilidades, de acordo com o teorema de Bayes, onde as estimativas de probabilidade são feitas sobre os resultados de uma distribuição conhecida (distribuição a priori). A cada iteração, a probabilidade P(X|Y) é realimentada ao modelo, passando a ser considerada como uma nova distribuição a priori. Esse processo se repete continuamente, permitindo a atualização constante das informações. Quando aplicado a algoritmos de Machine Learning, esse mecanismo favorece o aprendizado progressivo da rede e, consequentemente, o aprimoramento do desempenho dos dispositivos inteligentes conectados à infraestrutura 5G.

1.3.1 Objetivos gerais

Este trabalho propõe o desenvolvimento de um modelo estatístico, baseado em inferência bayesiana, para caracterizar o desvanecimento em canais de comunicação no espectro mmW (30–300 GHz), com o objetivo de aprimorar a previsibilidade do canal, superar limitações de modelos tradicionais e aumentar a confiabilidade de sistemas sem fio, especialmente em cenários com propagação predominantemente LOS

1.3.2 Objetivos específicos.

Analisar criticamente os modelos estatísticos clássicos de desvanecimento, como Rayleigh, Rice e Nakagami, quanto à sua aplicabilidade na faixa de mmW, identificando limitações físicas e matemáticas associadas à propagação em enlaces predominantemente com visada direta (LOS), e propor um modelo estatístico computacional, baseado no teorema de Bayes, que descreva adequadamente o fenômeno do fading nesse espectro e possa ser, fazendo uso das características bayesianas do modelo, incorporado a algoritmos de Inteligência Artificial e Machine Learning para otimizar a qualidade e a confiabilidade das comunicações.

1.3.3 Justificativa

Em consulta aos sites de referência e gerenciamento em publicações "Publish or Perish" (www.harzing.com) e "SciSpace Literature Review" (https://typeset.io) nenhuma proposição específica de modelamento completo para o fading utilizando fundamentos bayesianos é encontrada. Apenas alguns poucos trabalhos sobre situações pontuais e casos específicos são relatadas, como por exemplo os trabalhos de: (SHAN et al. 2020), o trabalho de (LAM 2016) e (ZHANG et al. 2020) que não tem um enfoque bayesiano mas trata de fading em mmW, (ALISON BETH 2011) que trata de fading em propagação sonora submarina mas utiliza de fundamentos bayesianos, (JARINOVÁ 2020) que usa cadeias de Markov na predição do fading no canal de Rayleigh. (ALEXANDROPOULOS et al. 2022) tratam do fading em superfícies inteligentes reconfiguráveis (RISs) em ambientes com alta densidade de antenas, característicos do 5G, usando estatística preditiva.

No geral, os poucos trabalhos que aparecem ligados ao tema são de análises pontuais e específicas, a pesquisa não aponta nenhuma publicação que trate da proposição de um modelo geral.

1.4 ESTRUTURA DO TRABALHO

Neste capítulo 1, procurou-se caracterizar de forma resumida o problema, a definição do que se pretende desenvolver e quais objetivos almejados.

No capítulo 2, é feita uma análise dos fatores de degradação do sinal, dos modelos de propagação, dos modelos de canais de comunicação e das técnicas de medição e modelamento.

O capítulo 3 especifica os modelos estatísticos de fading mais utilizados, os chamados modelos clássicos, salientando os prós e contras e fatores limitadores de cada um.

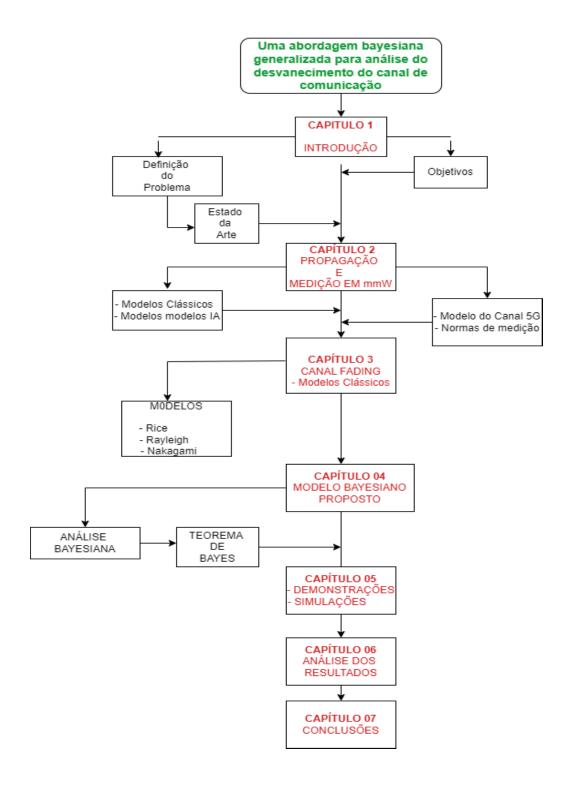
O capítulo 4 lança as bases da metodologia *bayesiana*, o teorema de *Bayes* e suas implicações.

No capítulo 5, considerando as definições do capítulo 3 e 4, é apresentado o desenvolvimento do modelo matemático, as simulações e validação.

No capítulo 6, os resultados são analisados e comparados, quando possível, aos modelos existentes.

As conclusões sobre os resultados obtidos e as sugestões de continuidade e aprimoramentos de novos modelos ou técnicas estão elencados no capítulo 7.

No fluxograma, procura-se mostrar de forma resumida como o trabalho será desenvolvido ao longo dos capítulos.



2 PROPAGAÇÃO E MEDIÇÃO EM *MMW*

Este capítulo aborda os mecanismos e modelos de propagação no espectro mmW, o canal de comunicação e os métodos de medição propostos para o 5G.

2.1 PROPAGAÇÃO

As características de propagação no espectro correspondente as ondas milimétricas (*mmW*) e sub-milimétricas diferem significativamente daquelas abaixo de 6 GHz, o que afeta fortemente o *design* das *Radio Access Network (RAN)*. As perdas de percurso devido à frequência, movimento relativo entre transmissor e receptor, o comportamento do sinal de rádio tendendo a ser mais próximo a um sinal óptico com menores índices de espalhamento e difração fica cada vez mais dependente da linha de visada (*LOS- line-of-sight*) e da reflexão sobre o espalhamento. Uma estação radio base (ERB) posicionada em alturas mais baixas e operando em frequências mais altas e tendo dependência do sinal *LOS* tem probabilidade muito maior de ser bloqueada, o sinal pode cair de forma significativa, rápida e imprevisível. Também, o bloqueio pode ser induzido por vegetação, mobiliário urbano, tráfego ou pessoas (SHARIAT et al. 2016).

Em frequências mais altas, mesmo pequenas diferenças em ângulos e comprimento de percurso *LOS* e percursos refletidos podem causar forte desvanecimento espacial até o ponto de total interrupção.

Grandes esforços já foram feitos e outros estão em andamento para desenvolver modelos avançados de propagação e de canal de forma a cobrir todo o espectro das *mmW* para vários cenários de implantação do 5G.

2.2 PROPAGAÇÃO NO ESPECTRO MMW

Devido aos comprimentos de onda curtos dos sinais no espectro *mmW*, variando entre 1 mm e 10 mm, seus mecanismos de propagação são drasticamente diferentes daqueles do espectro das micro-ondas e, portanto, devem ser cuidadosamente estudados e modelados para se entender o comportamento do canal *mmW* (HAMADEH et al. 2018). Enquanto sinais em bandas de frequência mais baixas podem se propagar por muitos quilômetros e penetrar mais facilmente através de

edifícios ou outros obstáculos, os sinais de ondas milimétricas podem viajar apenas alguns quilômetros ou menos e não penetram muito bem em materiais sólidos, também, sofrem enorme atenuação devido ao efeito do espaço livre FIGURA 1. No entanto, estas características de propagação das ondas milimétricas não são necessariamente desvantajosas, elas podem permitir um empacotamento mais denso dos links de comunicações, proporcionando assim uma utilização de espectro muito eficiente e, ainda, podem aumentar a segurança das transmissões.

Curvas de perda para diferentes frequências 220 30.0 GHz 60.0 GHz 200 120.0 GHz 240.0 GHz 180 Atenuação (dB) 160 140 120 100 80 10⁰ 10² 10³ 10⁵ 10¹ 10⁴ Distância (m)

FIGURA 1 - ATENUAÇÃO DO ESPAÇO LIVRE PARA DIFERENTES FREQUÊNCIAS

FONTE: O autor (2022)

De forma aditiva a todos os componentes que degradam as transmissões no espectro mmW, o aumento na frequência leva a implicações mais sensíveis em relação aos efeitos atmosféricos demandando maior sensibilidade no tratamento e análise dos links, ou seja, em sistemas de micro-ondas, a perda de transmissão é contabilizada principalmente pela perda de espaço livre. Porém, nas bandas de ondas milimétricas, fatores de perda adicionais entram em jogo, como perdas devido a absorção gasosa, vapor de água, moléculas de oxigênio presentes na atmosfera e chuva no meio de transmissão.

2.3 PERDAS POR GASES ATMOSFÉRICOS

A atenuação atmosférica é causada pela vibração molecular dos gases quando expostos a rádio frequência. As moléculas, principalmente de água e oxigênio

presentes no meio, absorvem parte da energia do sinal eletromagnético e vibram com intensidade dependente da frequência da portadora. A absorção pelos gases atmosféricos é diretamente influenciada por fatores como temperatura, pressão, altitude e principalmente pela frequência do sinal transmitido coincidindo com as frequências ressonantes das moléculas do gás (MARCUS; PATTAN 2005).

A FIGURA 2 mostra um gráfico expandido da absorção atmosférica versus frequência ao nível do mar onde a densidade do vapor de água é de 7,5 g/m³ à temperatura de 15°C. O nível do mar é o pior cenário de atenuação atmosférica, pois nesta altitude a densidade do ar é máxima e vai reduzindo com o aumento da altitude e consequentemente reduzindo as perdas.

Essa figura mostra, também, vários picos que ocorrem devido à absorção do sinal de rádio por vapor d'água e oxigênio (O_2) . Nessas frequências, a absorção resulta em alta atenuação do sinal de rádio e consequente curta distância de propagação. Para a tecnologia atual, os picos de absorção importantes ocorrem em 24 e 60 GHz.

As regiões espectrais entre os picos de absorção fornecem janelas onde a propagação pode ocorrer com maior eficiência (menores perdas). As janelas de transmissão estão em cerca de 35 GHz, 94 GHz, 140 GHz e 220 GHz (FEDERAL COMMUNICATION OFFICE OF ENGINEERING AND; TECHNOLOGY - 1997).

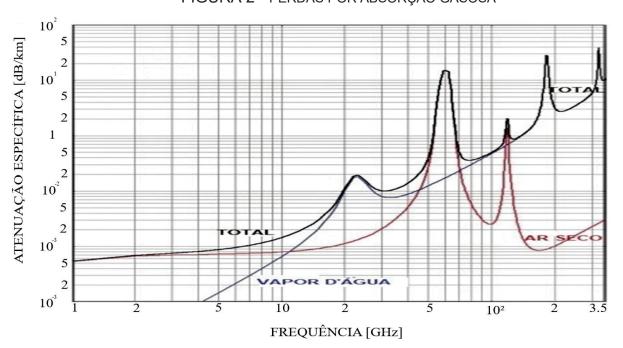


FIGURA 2 - PERDAS POR ABSORÇÃO GASOSA

FONTE: Adaptado de FCC (Federal Communication Commission) - 1997

As ressonâncias da $H_2\mathcal{O}$ e \mathcal{O}_2 foram estudadas extensivamente para fins de prever características de propagação no *range* das ondas milimétricas.

2.3.1 Desvanecimento causado por chuvas

As atenuações causadas pela interação do sinal propagante em *mmW* com as gotas de chuva não podem ser negligenciados. O comprimento de onda do sinal, de 1,0 mm a 10,0 mm, corresponde ao tamanho médio da gota de chuva e é mais vulnerável a sofrer bloqueio quando comparado, por exemplo, a sinais na faixa das micro-ondas.

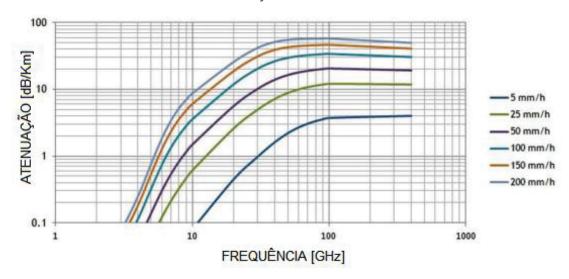


FIGURA 3 - ATENUAÇÃO CAUSADA POR CHUVAS

FONTE: Adaptado de ITU (International Telecommunication Union)

Claramente se observa que a atenuação específica da chuva (η_{Rain}) a uma dada taxa R de chuva em mm/h cresce exponencialmente até uma frequência crítica, tanto para índices leves quanto pesados de chuvas, além dessa frequência a atenuação se estabiliza ou mesmo decai levemente. As curvas são plotadas de acordo com a relação:

$$\eta_{Rain_{[dB/Km]}=KR^{\alpha}} \tag{2.01}$$

Onde K e α são função da frequência f de operação na faixa entre 1 $GHz \leq f \leq 1000~GHz$ e de parâmetros como temperatura, polarização e altitude (INTERNATIONAL TELECOMMUNICATION UNION - 2005).

2.4 PERDAS DEVIDO A VEGETAÇÃO

Em frequências de ondas milimétricas as perdas devido a presença de vegetação são muito significativas. Na verdade, pode ser um fator limitante da propagação em alguns casos. Devido a estrutura complexa da vegetação composta por troncos orientados aleatoriamente, ramos, galhos e folhas, o processo físico envolvido na propagação da onda de rádio através da vegetação é complexo. Além disso, a vegetação, sofre de forma mais pronunciada, a contribuição dos efeitos do ambiente, fatores como vento, precipitação de chuva ou neve e umidade alteram o cenário de forma profunda (RAHIM et al. 2017).

A fórmula geral de atenuação devido a vegetação proposta pela (ITU-R (2013) é expresso como:

$$\eta_{Foliage[dB]} = \alpha f^{\beta} D_f^c (\theta + E)^{\epsilon}$$
 (2.02)

onde f é a frequência MHz, D_f é a extensão ou profundidade da vegetação em metros e os parâmetros de regressão α , β , c, θ , E e ϵ são parâmetros empíricos que dependem do modelo de propagação usado. O ITU-R propõe utilizar um modelo simplificado onde $(\theta + E)^{\epsilon} = 1$, $\alpha = 0.5$, $\beta = 0.3$ e c = 0.6 então a atenuação fica sendo:

$$\eta_{Foliage[dB]} = 0.5 f^{0.3} D_f^{0.6} \tag{2.03}$$

Este modelo pode ser utilizado para distancias até 400 m. Também, o efeito da significante e profunda atenuação causada pela vegetação pode ser reduzido pelo uso de técnicas alternativas, como comunicação cooperativa, onde vários transmissores cooperam para entregar dados a um receptor bloqueado com folhagem excessiva ou usando estações retransmissoras na copa de árvores grandes ou múltiplas (HAMADE et al. 2018).

2.4.1 Penetração em obstáculos

Mesmo não havendo linha de visada direta entre o transmissor e o receptor, o sinal ainda pode ser recebido por meio de reflexões, difração ou espalhamento em objetos nas proximidades do receptor. Os comprimentos de onda curtos de sinais de ondas milimétricas resultam em baixa difração. Como ondas de luz, os sinais estão mais sujeitos a sombras e reflexões. Normalmente, para *NLOS* (sem visada direta), a maior contribuição no receptor é a potência refletida. As reflexões e a quantidade

associada de difusão do sinal são fortemente dependentes da refletividade nos obstáculos. Comprimentos de onda mais curtos (mais altas frequências) fazem com que o material refletor pareça relativamente "áspero", o que resulta em maior difusão do sinal e menos reflexão especular (ou seja, direta). Então, a difusão ou espalhamento fornece menos potência no receptor do que a potência refletida especular.

A perda por penetração de alguns materiais, por exemplo, tijolo, vidro colorido e o corpo humano aumentam consideravelmente à medida que a frequência aumenta. Comparado com sinais de microondas, sinais de ondas milimétricas não penetram bem nesses materiais. Por exemplo, as perdas de penetração de vidro colorido e tijolo na banda de frequência de 28 GHz foram medidos como 40,1 e 28,3 dB, respectivamente (ZHAO et al. 2013). Além disso, os experimentos mostram que o corpo humano causa uma perda de penetração entre 18 e 36 dB (COLLENGE et al. 2004). Isso significa que os humanos podem ser uma das principais causas de bloqueios em links de ondas milimétricas.

Além disso, os sinais podem chegar ao receptor via uma série de direções discretas devido às características limitadas de difração da onda milimétrica. A conectividade intermitente, devido a bloqueios, degrada significativamente a qualidade do serviço. Manter conexões de rádio contínuas na presença de objetos em movimento, por exemplo humanos, é um sério desafio no desenvolvimento de comunicações confiáveis no espectro das mmW (RANGAN et al. 2014).

2.4.2 Efeito Doppler

O efeito *Doppler* resulta em dispersão da frequência causada pela mobilidade relativa entre o transmissor e o receptor, é proporcional a velocidade entre ambos e a frequência do sinal. O efeito *Dopple*r em *mmW* é significativamente mais alto do que em frequências na faixa de micro-ondas. Por exemplo, o desvio *Doppler* em 30 GHz e 60 GHz é 10 e 20 vezes maior do que 3 GHz, podendo atingir 16 KHz a uma velocidade de 80 km para um sinal de 60 GHz. A dispersão de frequência gera um incremento de ocupação na largura da banda base que pode variar de forma lenta ou rápida no tempo dependendo do movimento relativo entre transmissor e receptor. No entanto, esse valor pode ser reduzido significativamente invocando antenas direcionais que reduzem as componentes multipercurso angulares de entrada (WEI 2014).

Considerando-se um móvel movendo à velocidade constante V ao longo de um percurso de comprimento l entre dois pontos A e B enquanto recebe sinal de uma fonte remota S conforme FIGURA 4, a diferença percorrida pela onda vinda da fonte S até o móvel nos pontos A e B é expressa por: $\Delta l = dcos\theta = V \Delta tcos\theta$, sendo Δt o tempo que o móvel gasta para se deslocar de A até B e θ assume-se como sendo o mesmo em ambos os pontos considerando-se que a fonte S está situada a grande distância.

A B

FIGURA 4- DIAGRAMA ESQUEMÁTICO EFEITO DOPPLER

FONTE: Adaptado de BELLONI, (2004)

A mudança de fase ($\Delta \phi$) no sinal recebido devido a diferença do comprimento dos caminhos entre os pontos A e B é:

$$\Delta \varphi = \frac{2\pi \Delta l}{\lambda} = \frac{2\pi V \Delta t}{\lambda} . \cos \theta \tag{2.04}$$

A aparente mudança de frequência ou efeito Doppler é dada por:

$$f_d = \frac{1}{2\pi} \cdot \frac{d\varphi}{dt} = \frac{\mathbf{V}}{\lambda} \cos\theta \tag{2.05}$$

Então, o efeito *Doppler* está relacionado à velocidade do móvel e ao ângulo espacial entre a direção do movimento e a direção de propagação da onda. Se o móvel tem movimento em direção à chegada da onda, o efeito *Doppler* é positivo, isto é, a frequência recebida aparentemente sofre um acréscimo e de forma similar, se o movimento é contrário a chegada da onda, a frequência recebida aparentemente sofre um decréscimo. Também, o multipercurso contribui para o efeito *Doppler* do sinal recebido.

2.4.3 Ruídos atmosféricos (temperatura de brilho) no espectro mmW

Também, constituintes da atmosfera que causam atenuação, como vapor d'água, oxigênio e chuva, irradiam sinais, por vibração molecular, semelhantes a ruído. Quando esses sinais chegam à antena do receptor, eles degradam o desempenho do sistema. Uma antena de estação terrestre apontada para um satélite em um alto ângulo de elevação irá captar o ruído do céu proveniente de constituintes atmosféricos (e outras fontes). Isso é conhecido como temperatura de ruído do céu ou temperatura de brilho. Para ângulos de baixa elevação, o ruído dominante será principalmente o do ambiente de propagação e será captado pelos lóbulos laterais da antena.

A FIGURA 5 mostra a temperatura de ruído do céu em função da frequência. O ruído atinge o pico na frequência de ressonância própria da molécula e este fenômeno também afeta a adequação da *mmW* a determinadas regiões do espectro para aplicações em comunicações (SMITH 1982).

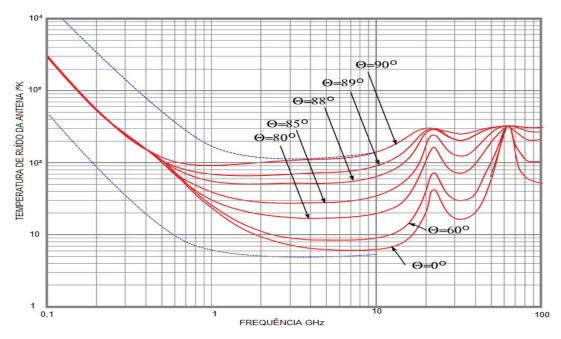


FIGURA 5 – TEMPERATURA DE RUÍDO DA ANTENA

FONTE: Adaptado de ITU – CCIR (International Radio Consultive Commitee)

O ruído que entra em no receptor vindo da antena é comumente referido como o ruído de temperatura da antena e inclui os componentes de ruído do céu.

2.5 MODELOS DE PROPAGAÇÃO USANDO IA (INTELIGENCIA ARTIFICIAL) E APRENDIZADO DE MÁQUINA.

Os modelos de perda de percurso existentes, empíricos, determinísticos ou semi-determinísticos adotam um modelo de distância logarítmica linear, que é derivado empiricamente assumindo uma proporcionalidade linear entre distância e a perda de propagação e determinando um fator de proporcionalidade por meio da análise de regressão linear adequada dos dados. O modelo de distância logarítmica linear é, geralmente, simples e tratável, mas não garante um desempenho preciso de previsão de perdas para todos os ambientes de propagação. Métodos de modelagem avançados são necessários para representar com maior precisão e flexibilidade a perda de percurso para ambientes complexos e diversos.

O uso de métodos de IA (inteligência artificial), estão sendo aplicados no campo da comunicação sem fio. O aprendizado de máquina é um conjunto de métodos baseados em um amostras de dados e algoritmos de modelagem para fazer previsões. Esta técnica é utilizada. no reconhecimento de imagem, processamento natural de linguagem e muitos outros campos.

Estudos recentes têm investigado o uso de aprendizado de máquina para a previsão de modelos de perda de percurso, o resultado desses estudos mostrou uma redução positiva na complexidade, quantidade de tempo necessária na medição e um aprimoramento nos modelos. Além disso, o *deep learning* também é usado para modelar a perda de percurso, em comunicações 5G, modelando a influência de objetos estáticos e em movimento, como veículos e pessoas (ZHANG et al. 2018), (JO et al. 2020), (CHONG et al. 2021).

A abordagem de IA, para modelagem de perda de percurso, pode fornecer um modelo mais sofisticado que pode generalizar bem o ambiente de propagação, uma vez que o modelo está sendo aprendido por meio de treinamento com os dados coletados do ambiente.

Modelos baseados em aprendizado de máquina usando princípios de IA (inteligência artificial) estão buscando aprimorar práticas e modelos disponíveis combinando técnicas como (JO et al. (2020), (ALKHATEEB et al. 2019):

 ANN – Redes Neurais Artificiais (Artificial Neural Network) - ANN é um sistema de regressão não linear baseado no aprendizado ponderado da rede através de dados obtidos de pré-processamentos, sua precisão depende dos dados de treinamento introduzidos. Um conjunto de dados bem distribuído, suficiente e medido com precisão são pré-requisitos para adquirir um modelo preciso. O objetivo da aprendizagem é encontrar os melhores pesos em dados de aprendizagem fornecidos que permitem uma previsão precisa. O fator-chave para obter os pesos com precisão é normalizar a magnitude dos valores de entrada, o que minimiza os efeitos colaterais de diferentes escalas. O modelo *ANN* supera o modelo de regressão polinomial no desempenho de predição e lida com mais dimensões do que os métodos lineares. Considerando a propagação complexa devido às alturas flutuantes e distribuição complexa de edifícios em áreas urbanas, o modelo não linear pode se ajustar melhor à regressão linear. A função de logística sigmoide funciona como uma função de ativação dentro de redes *ANN*, (JO et al. 2020).

- Análise da variância baseada em processos gaussianos (Modelo de sombreamento) Tradicionalmente, o sombreamento era tratado como um coeficiente com distribuição normal, pois é difícil generalizar as características dos obstáculos e, geralmente, seus efeitos na análise da perda de percurso são triviais. No entanto, em ambientes externos com vários obstáculos, o efeito de sombreamento desempenha um papel significativo na análise de previsão de perda de percurso exigindo alto nível de confiança em sua predição.
- PCA Princípio da Análise de Componentes É uma técnica de redução de dimensão que transforma linearmente o espaço original em um novo espaço de dimensões menores, ao mesmo tempo em que descreve a variabilidade dos dados. Na verdade, o PCA projeta ao longo dos autovetores da matriz de covariância correspondente aos maiores autovalores, onde os autovetores apontam na direção com a maior quantidade de variação de dados. Além disso, a magnitude dos autovalores pode ser usada para estimar a dimensão intrínseca dos dados. Na verdade, se *x* autovalores têm uma magnitude muito maior do que os restantes, o número x pode ser considerado a verdadeira dimensão dos dados.

Claramente, uma técnica linear é capaz de apenas extrair correlações lineares entre as variáveis, ao passo que, geralmente, superestima a dimensão intrínseca para os dados com relações complexas (GLAROT et al. 2011), (JO et al. 2020).

2.6 O CANAL DE COMUNICAÇÃO

A propagação do canal de rádio pode ser afetada por pequenos objetos ou obstáculos devido ao curto comprimento de onda das frequências utilizadas na banda *mmW*. Os modelos de canal podem ser classificados em modelos analíticos e modelos físicos

Os modelos analíticos caracterizam o canal de comunicação matematicamente e podem ser derivados de modelos físicos baseado em correlação, em propagação, modelos de entropia máxima e representação de canal virtual. Este, basicamente, usado para desenvolvimento de algoritmos e análise de sistema.

Os modelos de canal físico são construídos com base no canal de rádio direcional duplo entre o transmissor (Tx) e o receptor (Rx) com base na propagação de ondas eletromagnéticas. Os modelos de canais físicos podem ser classificados em determinísticos, estocásticos e estocástico baseado em geometria. Modelos determinísticos de canal caracterizam a propagação do sinal em um determinado ambiente físico com base em suposições de mecanismos de propagação. Esses modelos requerem uma geometria detalhada do ambiente, bem como dos parâmetros eletromagnéticos do meio. A propagação é calculada usando métodos baseados em raios ou resolvendo as equações de Maxwell com métodos de onda completa como o método dos momentos ou o método do domínio do tempo das diferenças finitas (HARRINGTON 1993), (YEE 1966) . O método de onda completa tem alta precisão, mas demanda grande esforço computacional. Nos modelos baseados em raios, estes são lançados cobrindo toda a esfera (3D) ou círculo (2D) ao redor do transmissor e traçados até chegarem ao Rx.

Por outro lado, os modelos estocásticos visam descrever o comportamento dos canais de propagação estatisticamente, sem assumir a geometria do ambiente; os parâmetros do canal de rádio são definidos por funções de distribuição de probabilidade, que podem ser sintonizadas com base em medições do canal ou modelagem determinística. Um exemplo é o modelo estocástico de Saleh-Valenzuela

que assume que as ondas de rádio chegam ao receptor em grupos concentrados de componentes multipercurso, chamados *clusters*.

No modelo de canal estocástico geométrico o canal de propagação do transmissor para o receptor é caracterizado deterministicamente, mas as localizações e propriedades dos objetos dispersores são escolhidos de forma estocástica.

Recentemente, modelos de canal *mmW* baseados em mapa foram propostos, como um modelo estatístico 3-D para 5G (SAMIMI; RAPPAPORT 2016).

2.6.1 Medição do canal

O método mais direto de estudar a propagação das ondas de rádio é por meio de medições de canal, que irá obter modelos estatísticos que verifiquem os modelos teóricos de propagação. Diferentes técnicas de medição com várias configurações experimentais têm sido usadas para estudar os diferentes aspectos dos canais de radiofrequência (RF). Eles geralmente podem ser classificados como técnicas de banda estreita (NB) e banda larga (WB) com base na relação entre a largura de banda do sinal de teste e a largura de banda de coerência do canal.

2.6.2 Medição em banda estreita (*NB*)

É usada para medir as perdas de percurso, desvanecimento de banda estreita, fading de pequena escala e espalhamento *Doppler*. A simplicidade desta técnica é a principal vantagem das medições em *NB*. Uma onda contínua (*CW*) é transmitida em técnicas de banda estreita e a potência recebida é medida no espaço ou no tempo. A principal desvantagem desta técnica é que o sinal recebido representa apenas o envelope da soma dos vetores das componentes multipercurso; não mostra uma informação quantitativa das componentes. Portanto, se a largura de banda do sinal for alta, a técnica de medição em banda larga (*WB*) deve ser usada para estimar os parâmetros de dispersão de tempo do canal.

Gerador de Sinais

Tx Rx

Analisador de Espectro

FIGURA 6 - DIAGRAMA DE BLOCOS MEDIÇÃO BANDA ESTREITA

FONTE: O autor

O diagrama de blocos básico de medição em banda estreita (NB) é mostrado na FIGURA 6.

2.6.3 Medição em banda larga (WB)

As técnicas de medição de banda larga do canal quantificam cada componente multipercurso e fornece parâmetros de dispersão temporal. Para extrair os parâmetros de dispersão de tempo, as medições de um tom de teste são executadas. O tom de banda larga transmitido pode ser no domínio da frequência ou do tempo, onde a transformada de *Fourier* é usada para converter entre frequência e domínio do tempo.

No domínio da frequência, a função de transferência do canal é medida usando um *Vector Network Analyzer* (*VNA*), onde se mede a resposta de frequência complexa. O diagrama de blocos para um sistema baseado em medição por *VNA* é mostrado na FIGURA 7. Usando o sistema *VNA*, o canal é medido em tons de diferentes frequências junto com a largura de banda do sistema usando varredura de frequência escalonada.

Consequentemente, uma grande largura de banda resulta na medição mais lenta do canal. Então, o *VNA* deve ser usado apenas para canais de variação lenta no tempo (LI et al. 2017).

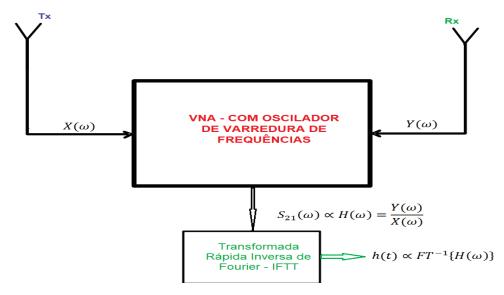


FIGURA 7 - MEDIÇÃO VNA COM VARREDURA DE FREQUÊNCIA

FONTE: O autor ADAPTADO DE (AL-SAMAN et al. 2021)

A medição no domínio do tempo fornece uma abordagem mais direta. Essa técnica de medição usa um gerador de pulso para transmitir pulsos curtos da ordem

de nanossegundos varrendo a largura de banda do canal de banda larga, enquanto um osciloscópio digital de amostragem é usado para registrar o sinal recebido. Esta técnica de medição é eficiente para variações rápidas do canal, no entanto, é um desafio gerar pulsos curtos com potência adequada para alcançar sinais recebidos de boa gualidade.

A técnica de medição mais eficaz na abordagem do domínio do tempo usa correlação de tons de teste injetados no canal. Neste método, uma sequência de pulsos, como uma sequência de pseudo ruído (*PN*) é enviada pelo Tx, enquanto na parte Rx, a correlação cruzada entre os sinais transmitidos e recebidos são usados para extrair o canal. Como Tx e Rx estão separados no domínio do tempo podem ser usados para longa distância, embora a sincronização seja um desafio. A abordagem do canal de correlação é baseada na suposição de que a taxa de clock da sequência de pulsos é a mesma no Tx e Rx para processamento de correlação em tempo real (AL-SAMAN et al. 2021).

Rx Tx $f_c - f_I$ **Gerador Sinal** Digitalizador de teste Banda Larga **Gerador Sinal** Controle de Teste Correlação **RESPOSTA DO CANAL AO IMPULSO**

FIGURA 8 - MEDIÇÃO CORRELAÇÃO DE BANDA LARGA NO DOMÍNIO DO TEMPO

FONTE: O autor ADAPTADO DE (AL-SAMAN et al. 2021)

Esta técnica permite uma alta velocidade de medição, porém demanda um digitalizador de banda larga.

2.7 O CANAL DE COMUNICAÇÃO EM MMW

Como já afirmado, os modelos de canais sem fio podem ser divididos em três categorias:

- Modelo de canal determinístico;
- Modelo de canal estocástico;
- Modelo de canal híbrido (modelo estocástico combinado e modelo baseado em mapa).

Em sistemas *wireles*s em *mmW* os modelos estocásticos adquirem maior importância por permitirem mais fácil e rápida simulação.

2.7.1 Modelos estocásticos em mmW

Modelos de canais estocásticos estão em constante desenvolvimento para se adaptar aos novos recursos de sistemas de comunicação sem fio. São os modelos de canal mais amplamente usados na simulação de sistemas. Não são projetados para prever corretamente a resposta ao impulso em um local específico, mas podem ser usados para prever a função de densidade de probabilidade (FDP) em uma grande área. Este tipo de modelo se baseia em observações estatísticas dos canais com várias medições em diferentes cenários típicos. As distribuições características do canal são estimadas a partir de medições (XIAO et al. 2017).

A principal linha de pesquisa de modelos de canais segue a linha de desenvolvimento do 3GPP-SCM, SCM significa modelo de canal espacial (3GPP é uma organização tecnológica que visa padronizar a criação, envio e reprodução de arquivos multimídia em telefones celulares e também em outros aparelhos wireless) (3GPP TR 25.996 2018), WINNER-I / II / + (KYOSTI et al. 2008) e, em seguida, 3GPP-3D (3GPP TR 36.873 2014) e 3GPP-NR (3GPP T.R. 38.901 2018). Esses modelos cobrem a maioria dos aspectos de canais sem fio em vários cenários, que incluem layout de rede, parâmetros de grande e pequena escala e transição de cenário. Foram desenvolvidos e propostos depois de 2003.

2.7.2 Modelos híbridos

É uma abordagem de modelagem de canal estocástica e determinística combinada que é chamado de modelo de canal híbrido METIS (ICT-317669-METIS/D1.4 2015) normalmente, no procedimento de modelagem do canal, as

localizações das estações base e o equipamento do usuário devem ser primeiramente fixados em um mapa. A perda de percurso e o sombreamento são calculados com base no mapa e objetos aleatórios de sombra podem ser gerados com base no método de modelagem de traçado de raio, então, todos os outros cálculos são feitos pelo modelo estocástico. A abordagem de modelagem híbrida leva os méritos de ambos os fatores, determinísticos e estocásticos, e é amplamente aceito na modelagem de canais *mmW* (ICT-671650-mmMAGIC/W2.1 2016).

2.8 MODELAMENTO DO CANAL MMW

A parceria público-privada de infraestrutura 5GPP (5G INFRASTRUCTURE PUBLIC PRIVATE PARTNERSHIP - 5G PPP 2021) está assumindo a liderança da Europa na padronização das comunicações 5G e a pesquisa de canais mmW é uma das áreas mais importantes. Os modelos de canal mmW foram desenvolvidos sobre as bases da norma WINNER com a inclusão da maioria dos aspectos dos canais mmW em cenários diferentes. As metodologias, como a abordagem de modelagem de canal estocástico, de traçado de raio e a abordagem de modelagem híbrida, são todos adotados no desenvolvimento desses modelos, como 5GCM, IEEE 802.11ay (PUDEYEV et al. 2016), (IMT 2020 JIANHUA 2020) e New York University wireless model (NYU-NEW YORK UNIVERSITY 2014). Empresas de renome como Samsung, Electron Co, Intel, Huawei Technologies Co, NTT Docomo, além de universidades e institutos de tecnologia também participam do consórcio.

2.8.1 O canal mmW padrão

Existem alguns modelos de canal padrão que suportam cenários de canal *mmW* como IEEE 802, MiWEBA, METIS, MCHFB (5GCM), 3GPP, *mmMagic* podem ser usados para modelar canais mmW. Na comparação entre esses, podemos descobrir que existem alguns métodos de medição e modelagem comuns, isso basicamente porque esses modelos são desenvolvidos em paralelo e os parceiros pertencem a projetos que contribuem ativamente entre si. Por exemplo, os parceiros do projeto *mmMagic* também contribuem para os projetos 3GPP. No entanto, cada modelo individual tem contribuições exclusivas.

2.8.1.1 Modelos IEEE 802.11ad & IEEE 802.15.3c

Os modelos IEEE 802.11ad (MALTSEV et al. 2010), (PUDEYEV et al. 2016) são modelos de canal propostos para a faixa de frequência de 60 GHz em cenários indoor. O IEEE 802.11ad é um modelo 3D e IEEE 802.15.3c é um modelo 2D, desenvolvidos para diferentes cenários.

O modelo IEEE 802.11ad foca na modelagem dos canais em *Wireless Local Area networks* (*WLAN*) em cenários como salas de conferências, sala de estar e ambientes menores. O modelo IEEE802.15.3c foca na modelagem dos canais em *Wireless Personal Area Networks* (*WPAN*) em cenários como residências, escritório, biblioteca, área de trabalho e pequenos centros comerciais.

Ambos os modelos são baseados na abordagem de modelagem de *cluster* ou feixe de raios, que é semelhante ao modelo de Saleh-Valenzuela (SV) (VALENZUELA; SALEH 1987), onde as amplitudes e atrasos são descritos por distribuições estatísticas. Embora ambos tenham sido desenvolvidos com base em parâmetros estatísticos estimados a partir das medições e traçado de raios eles não são exatamente os mesmos que o modelo híbrido *METIS* devido suas metodologias de modelagem. Por exemplo, distribuições estatísticas empíricas são amplamente utilizadas na modelagem de atrasos de feixes e ângulos no modelo IEEE 802.11ad o qual é classificado de modelo quase determinístico (MALTSEV et al. 2014).

2.8.1.2 Modelo METIS

Os modelos de canal *METIS* foram desenvolvidos com base em extensas revisões da literatura, análise massiva de dados de medições reais e simulações de traçado de raio. Os modelos desenvolvidos são para cenários 5G gerais, que incluem as características de canais *MIMO* massivos e canais *mmW*. O modelo *METIS* usa também modelagem baseada em mapa, modelos estocásticos e modelos híbridos. Assim, o usuário pode fazer escolhas, dependendo se o cenário de propagação pode ser modelado com mais de um método de modelagem. A escolha do modelo depende da faixa de frequência, precisão, complexidade computacional e tempo de simulação (que depende principalmente do sistema simulado, como o número de estações base e equipamentos de usuários). (RASCHKOWSKI et al. 2015).

Na comparação dos modelos *METIS*, os modelos baseados em mapas são os mais completos e cobrem a maioria dos casos de teste, cenários de propagação e faixa de frequência. Modelos de canal *mmW* baseados em mapa abordam a faixa de frequência até 100 GHz e as larguras de banda dos canais *mmW* de até 10% da frequência central. O modelo estocástico se adapta melhor a macros e microambientes de células urbanas, incluindo cenários de comunicação do exterior para exterior (*O20*) e exterior para interior (*O2I*). O modelo híbrido é uma combinação de ambos. Pode ser considerado como uma estrutura flexível e escalonável para atender aos requisitos de modelamento ou simulação de canais.

2.8.1.3 Modelo mmMagic

O modelo de canal *mmMAGIC* é um modelo estocástico baseado em geometria, sua estrutura de modelagem e recursos estendem sua precisão e aplicabilidade. As características do modelo são os estudos de reflexão no solo, o bloqueio causado por edifícios e outros obstáculos que geram perdas de penetração, grandes larguras de banda, conjunto de antenas e consistência espacial.

Especificamente, é um modelo baseado no trabalho *METIS* desenvolvido com base na fórmula de difração de *Kirchhoff* e verificada com medições reais tendo por finalidade principal a análise de perdas causadas por bloqueios. O procedimento de verificação da consistência espacial do modelo foi iniciado pelo 3GPP, usando ângulos variantes no tempo e feixe intermitente conforme movimento do usuário. Também, o modelo é um importante recurso para avaliar a mobilidade e o rastreamento do feixe e as características do *fading* em pequena escala causados pelas componentes difusas do sinal relacionados a rugosidade da superfície de vários materiais de construção

2.8.1.4 Modelo 3GPP

Os modelos 3GPP são modelos generalizados de canais baseados em métodos de modelagem utilizados desde o desenvolvimento dos modelos *WINNER*. É um modelo em nível de sistema incluindo todos os aspectos relacionados ao canal relacionados a parâmetros de larga e de pequena escala. Também inclui os modelos de tempo de atraso de propagação do feixe gerado por multipercursos, aspectos

fundamentais para avaliação do *link* e calibração do modelo do canal. Este modelo tende a ser uma referência de base para a indústria, institutos de pesquisa e academia no desenvolvimento de simuladores de canais (3GPP T.R. 38.901 2018).

No 3GPP NR, modelo mais recente desenvolvido para operar em frequências acima de 6 GHz, existem modelos estocásticos e híbridos baseados em mapas e aptos a suportar canais *mmW*. Os cenários que os modelos estocásticos suportam incluem meios macro urbano (*UMa*), micro urbano (*UMi*) - corredores de ruas, *UMii*-praça aberta, interior de edifícios, escritórios e *shopping centers* e macro rural (*RMa*). Exceto para modelar características do canal relacionadas à perda de percurso, probabilidade de *LOS*, penetração, desvanecimento rápido (modelo em pequena escala), etc.

As características específicas dos canais *mmW* são modeladas pela adição de componentes como absorção de oxigênio, bloqueio, correlação para simulações multi frequência. Os modelos, híbridos baseados em mapas, são compostos por um modelo determinístico (baseado no trabalho *METIS*) e um modelo estocástico correspondente ao mencionado anteriormente. A introdução de um mapa digital na simulação permite avaliar e prever o desempenho do sistema considerando os impactos dos tipos de materiais e de estruturas presentes no ambiente em consideração.

3 CANAL FADING - O MODELO CLÁSSICO

Neste capítulo tem-se a definição e características do efeito *fading* e os parâmetros a ele associados. Também, os modelos aceitos para a caracterização do canal *fading* suas limitações e particularidades.

3.1 O FADING

As comunicações por rádio em diferentes tipos de links (terrestres, terra-ar e ar-ar) ocorrem em diversas condições atmosféricas e ionosféricas, envolvendo várias componentes e variáveis. Essas comunicações são governadas por princípios físicos e processos complexos, que podem operar de forma correlata ou independente.

Um dos principais desafios enfrentados nas comunicações por rádio é o fenômeno *fading* ou desvanecimento do canal dinâmico, que é principalmente causado pelo efeito de multipercurso, espalhamento do sinal, estes determinantes na faixa até *UHF*, reflexão e efeito Doppler.

No espaço livre, os sinais de rádio se propagam na forma de ondas esféricas, com suas amplitudes se reduzindo inversamente proporcional à distância entre as antenas. Cada sinal de rádio é representado como uma onda eletromagnética se propagando em uma direção específica. As características principais de operação de uma antena, como a intensidade do campo, a polarização e a direção de propagação, são determinantes para uma comunicação eficiente (VAUGHAN; BACH ANDERSEN 2002).

No projeto de uma rede de comunicação, com ou sem fio, existe em essência três características principais independentes a serem consideradas no âmbito eletrônico e eletromagnético:

- Operação da antena transmissora incluindo a especificação do equipamento eletrônico que controla toda a operação de transmissão;
- Escolha do modelo e a análise das propriedades de propagação do canal que conecta as antenas transmissora e receptora;
- Estudo e análise de toda operação relativa ao receptor.

O canal de propagação é influenciado pelas obstruções nas proximidades das antenas e ao longo do percurso e, também, pelas condições ambientais ou climáticas.

A principal característica da resposta depende das condições de propagação do sinal nos diversos ambientes operacionais para os quais o *link* de comunicação é utilizado.

3.2 BANDA DE CORÊNCIA

Enquanto o atraso de propagação é um fenômeno natural causado por caminhos multipercursos e dispersos no canal a largura de banda de coerência B_c é uma relação derivada a partir do valor RMS do espalhamento. A largura da banda de coerência é uma medida estatística da gama de frequências sobre as quais o canal pode ser considerado invariante (ou seja, um canal que passa todos os componentes espectrais com ganho aproximadamente igual e fase linear). Em outras palavras, a largura de banda de coerência é a gama de freqüências sobre as quais duas componentes de freqüência têm um forte potencial de correlação de amplitude. Dois sinais com separação de freqüência maior que B_c são afetadas de forma bastante diferente pelo canal.

Se a banda de coerência é definida como a largura de banda sobre a qual a função de correlação de freqüência está acima de 0,9, então (S.RAPPAPORT 2018):

$$B_c = \frac{1}{50\sigma_t} \tag{3.01}$$

onde σ_t é a variancia.

É importante notar que uma relação exata entre a largura de banda de coerência e o valor *RMS* do atraso é função da resposta específica ao impulso do canal aos sinais aplicados. Em geral, técnicas de análise espectral e simulação são necessárias para determinar o impacto exato que o tempo dos caminhos multipercursos tem em um determinado sinal transmitido. Por esse motivo, modelos precisos de canais de multipercursos devem ser usados no design de modens específicos para comunicação sem fio.

3.3 ESPALHAMENTO DOPPLER E TEMPO DE COERÊNCIA

O espalhamento *Doppler* (B_D) é a medida do alargamento espectral causado pela taxa de variação do canal de rádio móvel e é definido como a faixa de frequências sobre as quais o espectro *Doppler* recebido é essencialmente não nulo. Quando um tom ou sinal puro senoidal de frequência f_c é transmitido, o espectro do sinal recebido,

chamado de espectro *Doppler*, terá componentes na faixa $(f_c - f_d)$ até $(f_c + f_d)$, onde f_d é o efeito *Doppler*. O valor do alargamento espectral depende, portanto, de f_d que é função da velocidade relativa do móvel e do ângulo θ entre a direção do movimento do móvel e a direção de chegada das ondas dispersas, FIGURA 4. Se a largura do sinal da banda base é maior que B_D o efeito do espalhamento *Doppler* não afeta o receptor e este é um canal de *fading* lento.

O tempo de coerência é o dual do *espalhamento Doppler* no domínio do tempo, é usado para caracterizar a natureza variável no tempo da dispersividade da frequência do canal. O espalhamento *Doppler* e *tempo de coerência* são inversamente proporcionais (VAUGHAN; BACH ANDERSEN 2002).

$$T_c \approx \frac{1}{f_d} \tag{3.02}$$

onde f_d é o máximo efeito *Doppler*.

O tempo de coerência é uma medida estatística da duração do tempo no qual a resposta do canal é essencialmente invariante e compara a resposta do canal em diferentes tempos, ou seja, o tempo de coerência é a duração de tempo no qual dois sinais recebidos têm forte correlação de amplitude. Se a largura de banda recíproca da banda base do sinal é maior que o tempo de coerência do canal, ele irá variar durante a transmissão do sinal causando distorções no receptor.

Matematicamente o tempo de coerência é definido como o tempo sobre o qual a função de correlação temporal é maior que 0,5, então, o *tempo de coerência* é aproximadamente:

$$T_c \approx \frac{9}{16\pi f_d} \tag{3.03}$$

onde f_d é o efeito *Doppler* ($f_d = V/\lambda$). Na prática, a equação (3.03) dá a duração de tempo no qual um sinal sob efeito *fading* pode flutuar amplamente.

A definição de tempo de coerência implica, portanto, que dois sinais chegando com separação maior que T_c são afetados diretamente pelo canal (TSAKALOZOS et al. 2010).

3.4 FONTES DE RUÍDO NO CANAL DE COMUNICAÇÃO

A eficiência dos *links* de radiocomunicação terrestre, atmosférico ou ionosférico, depende de paramêtros como: ruído nas antenas transmissora e receptora, ruído inerente aos equipamentos conectados às duas antenas e ruído de fundo, ruído do ambiente, radiação cósmica, variações atmosféricas, aqueles gerados pela atividade humana e devido ao efeito *Doppler* em comunicações móveis (JAKES 1984).

Em um canal *wireless* a fonte de ruídos pode ser subdividida em aditiva ou fonte de ruído branco e multiplicativa. O ruído aditivo é gerado dentro dos equipamentos transmissores e receptores, como ruído térmico ou por interações eletromagnéticas em componentes eletrônicos ativos ou passivos que compõem o circuito. Ou seja, o ruído aditivo é gerado no interior de cada um dos elementos componentes do canal de comunicação devido ao movimento randômico dos elétrons que compõem os elementos formadores dos equipamentos.

De acordo com a termodinâmica, a energia do ruído térmico é determinada pela média da temperatura ambiente, T_0 :

$$E_N = K_B T_0 \tag{3.04}$$

onde K_B =1,38.10²³ W.s/K é a constante de *Boltzmann* quando T_0 = 290 K (17°C).

Esta energia é uniformemente distribuída na banda de frequência, por isso, o fato de ser chamada de ruído branco.

A potência total efetiva do ruído na entrada do receptor é dada por:

$$N_F = K_B T_0 B_w F (3.05)$$

onde F é a figura de ruído no receptor e B_w é a largura da banda do sinal.

A figura de ruído representa qualquer ruído adicional relativo ao ambiente e é dado por:

$$F = 1 + \frac{T_e}{T_0} \tag{3.06}$$

sendo T_e a temperatura efetiva a qual leva em consideração os efeitos do meio ambiente (clima, ruído cósmico, chuvas etc.) e aqueles gerados pelo homem (indústrias, motores, usinas de potência, subestações etc.).

O ruído multiplicativo surge devido a vários processos dentro do canal de propagação e depende majoritariamente das características das antenas transmissora e receptora em relação à reflexão, absorção, espalhamento e difração causada pelas obstruções no percurso. Normalmente o processo multiplicativo no canal de propagação é dividido em três tipos: perdas de propagação ou de percurso, perdas de larga escala ou *slow fading* e de curta escala ou *fast fading* (JAKES 1984), a seguir descritos.

3.4.1 Perdas de propagação

Determina a eficácia do canal de comunicação em diferentes ambientes e define a amplitude da variação do sinal ou a intensidade dos campos ao longo da trajetória de propagação entre dois pontos dentro do canal. Em geral a perda de percurso é definida como sendo a diferença logarítmica da amplitude ou intensidade (potência) de dois pontos quaisquer r_1 (ponto de transmissão) e r_2 (ponto de recepção) no caminho de propagação.

É um decréscimo suave da intensidade do sinal, porém em larga escala ou profundo entre as antenas terminais. O processo físico que causa esse fenômeno é o espalhamento das ondas eletromagnéticas irradiadas no espaço pela antena transmissora e pelo efeito de obstruções de objetos naturais ou feitos pelo homem nas proximidades ou entre as antenas. É também afetada pelo ruído branco gerado pelos equipamentos de transmissão e recepção.

A variação espacial e temporal do sinal, na perda de percurso, é profunda e lenta, respectivamente.

3.4.2 Perdas de larga escala ou *slow fading*.

Ocorre em larga escala no domínio do espaço e lento no domínio do tempo. É causado principalmente por difrações em obstáculos ao longo do *link* ou nas proximidades das antenas, é também chamado de *slow fading* devido a áreas de sombra. Nesta região a variação randômica do sinal segue a distribuição de *Gauss* ou a distribuição log-normal.

A FDP (Função Densidade de Probabilidade) das variações do sinal com o correspondente desvio padrão dependem da natureza do terreno, das condições

atmosféricas e das características do ambiente de propagação (GHOSH; SUDIR 2014).

$$FDP(p) = \frac{1}{\sigma_L \sqrt{2\pi}} e^{-\frac{(p-\overline{p})^2}{2\sigma_L^2}}$$
(3.07)

onde p é a potência máxima da envoltória do sinal recebido e \bar{p} é o valor médio.

A FDA (Função de Distribuição Acumulada), caracteriza como as probabilidades são associadas aos valores ou aos intervalos de valores de uma variável randômica $[F(x) = P(X \le x)]$ e descreve o comportamento desta variável é dada por:

$$FDA(Z) \equiv P_r(p < z) = \int_0^z FDA(p)dr$$
 (3.08)

onde $\bar{p} = \langle p \rangle$ é o valor médio do nível do sinal randômico, p é o valor da potência do sinal recebido $\sigma_L = \langle p^2 - \bar{p}^2 \rangle$ é a variância ou potência média no domínio do tempo e Z é a margem de *slow fading* que produz o máximo efeito no sinal.

Slow fading ou desvanecimentos lentos são basicamente causados por zonas de sombras de prédios, montanhas ou outros obstáculos entre a estação base de antenas e o receptor

3.4.3 Desvanecimento rápido ou fast fading

Ocorre principalmente devido a reflexões ou espalhamentos em estruturas locais ou devido ao movimento do usuário em relação ao transmissor. A resposta do canal ao impulso muda rapidamente, ou em outras palavras, o tempo de coerência do canal T_C é menor que o período amostrado do sinal transmitido T ($T_C \ll T$). Isto causa dispersão de frequência ou *fading* seletivo no tempo, devido ao efeito *Doppler* (OLSEN et al. 2003).

No caso de situação dinâmica de multipercurso, onde as antenas do receptor/usuário estão em movimento em torno de estação base de antenas, a variação do sinal espacial resultante pode ser vista sofrendo variações temporais. O sinal recebido pelo receptor em movimento em qualquer ponto do espaço consiste em um amplo número de sinais tendo amplitudes, fases, ângulos de chegada e tempo de atraso randomicamente distribuídos e são dependentes da velocidade. Todas estas características mudam as fases relativas em função da localização no espaço e finalmente causam desvanecimento (fading) do sinal no domínio do espaço. No caso

da situação dinâmica, receptor em movimento, o *fading* no receptor móvel ocorre também no domínio do tempo. Estas variações temporais ou variações dinâmicas do tempo de percurso são relativas ao efeito *Doppler* o qual ocorre devido ao movimento relativo entre o usuário e a estação base (LAVANIA et al. 2016).

3.5 MODELOS DO CANAL FADING

Nas frequências até a faixa de *UHF* onde na propagação ocorrem altos níveis de reflexão, difração e principalmente espalhamento algumas funções de distribuição de probabilidade podem modelar o efeito *fast fading: Rayleigh, Rice, Suzuki, Nakagami...* dentre outras. A distribuição de *Rice* é a que descreve de forma mais geral o fenômeno em *links* terrestres com visada direta (LOS-*line-of-sight*) com espalhamento e difração bem como os *links* sem visada direta (*NLOS*).

3.5.1 O Modelo de Rice

O sinal que chega à antena receptora é formado pela somatória ou combinação de ondas vindas simultaneamente de diversas fontes (propagação multipercurso) que vetorialmente se compõem de forma construtiva ou destrutiva dependendo dos ângulos de fase dos sinais chegando no receptor.

A contribuição das componentes, geradas pelo multipercurso, em relação ao Sinal principal (*LOS*) no receptor pode, de forma intuitiva, ser avaliada por:

$$K = \frac{LOS}{MULTIPERCURSO} \frac{[POT\hat{E}NCIA]}{[POT\hat{E}NCIA]}$$
(3.09)

sendo K o parâmetro de Rice.

Para a distribuição de *Rice* a Função Densidade de Probabilidade (FDP) para a envoltória de tensão do sinal ou de sua potência é dada por:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\left(\frac{p^2 + A^2}{2\sigma^2}\right)} I_0\left(\frac{A.p}{\sigma^2}\right)$$
(3.10)

sendo σ o desvio padrão, A a máxima tensão ou envoltória da potência e I_0 é a função de Bessel modificada do primeiro tipo e ordem zero.

Como K é a relação entre a potência do sinal principal e as componentes secundárias geradas por multipercurso:

$$K = \frac{A^2}{2\sigma^2} \tag{3.11}$$

E a FDP de *Rice* pode ser escrita como:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}} e^{-k} I_0 \left(\frac{p}{\sigma} \sqrt{2k}\right)$$
 (3.12)

Por esta equação vê-se que o pior caso para o canal *fading* é quando K=0, não há sinal direto, portanto, o termo $e^{-K}=1$ e $I_0(0)=1$.

FIGURA 9 - FDP DE RICE PARA DIFERENTES VALORES DE K

FONTE: O autor (2023)

Na condição de boa visada entre transmissor e receptor (LOS) e na ausência de componentes multipercurso, fator que aumenta com o aumento da frequência de operação do link, nesta situação $K \to \infty$ o *fading* de *Rice* assume o formato da FDP *delta de Dirac* mostrado na FIGURA 9 (KUMAR et al. 2013).

Por esta análise fica claro que o modelo geral do *fading* de *Rice* não se aplica a enlaces operando em altas frequências, como na geração 5G por exemplo, onde a grande perda de propagação demandará alta densidade de antenas e devido à alta frequência de operação praticamente eliminará o efeito de espalhamento exigindo visada direta (LOS) entre transmissor e receptor.

3.5.2 O modelo Rayleigh

Em ambientes de propagação com ausência de sinal direto e a existência de grande nível de espalhamento, cenário típico de ambientes urbanos densos, a variação da amplitude do sinal no receptor varia de forma rápida e profunda. Nesta condição o fator K de Rice tende a zero $(K \to 0)$, de (3.12), o termo $e^{-K} = 1$ e $I_0(0) = 1$ e:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}} \tag{3.13}$$

Portanto, o modelo *Rayleigh* é derivado do modelo *Rice* na situação específica de links *NLOS* e com alto índice de multipercursos. A expressão (3.13) representa a FDP do modelo *Rayleigh*.

3.5.3 O Modelo Nakagami

Em comunicações móveis utilizando *mmW*, como os links serão quase sempre *LOS*, busca-se um modelo que elimine o efeito do *K* de *Rice*, ou seja, que não leve a valores nulos ou infinitos, o delta de *Dirac*.

Um possível modelo que atende a essa necessidade é a distribuição Nakagami, baseada na distribuição Gama (Γ), que possui dois parâmetros: forma e controle do espalhamento.

3.5.3.1 A Distribuição Nakagami

É uma distribuição contínua de probabilidades fundamentada na distribuição gama e tem dois parâmetros: forma α e escala Ω e faz parte da família de distribuição de cauda longa (BATTACHARIA et al. 2010) (SHARMA; MISHRA 2015).

$$f(x) = \frac{2m^m}{\Gamma(m)\Omega^m} y^{2m-1} e^{-\frac{m}{\Omega}y^2}$$
(3.14)

onde Ω é o parâmetro de controle de escala $(\Omega > 0)$, m é o parâmetro de forma (m > 0,5) determina a profundidade do *fading* e a extensão da cauda da distribuição, y é a variável aleatória que representa a amplitude do sinal.

A resposta do canal é um valor complexo. Para o canal fading de *Nakagami-m*, ele pode ser representado por:

$$Z = X + jY = M. e^{j\theta} \tag{3.15}$$

onde X e Y e representam as componentes de fase, M é o envelope do canal fading e θ é a fase.

Na equação 3.14, sendo $\Omega = E[S2]$ o valor da potência média, E o operador de expectativa e S a raiz quadrada da soma do quadrado da amplitude quando m é um inteiro. Então, α é o inverso da variância normalizada S2.

$$m = \frac{(E[S^2])^2}{Var(S^2)} = \frac{\Omega^2}{Var(S^2)}$$
 (3.16)

onde m assume valores entre [1/2, ∞].

Dependendo do valor de m, a distribuição Nakagami-m assume algumas particularidades; quando m tende ao infinito, o canal tende a um canal estático (LOS); ou seja, não há ocorrência de desvanecimento.

Quando m tende a 1, a distribuição Nakagami-m torna-se a distribuição de Rayleigh, e para os valores de m>1 Nakagami-m aproxima-se da distribuição de Rice.

A relação entre o fator K de Rice e o parâmetro m , parâmetro de forma de Nakagami, mantém a seguinte relação:

$$m = \frac{(K+1)^2}{2K+1} \qquad \text{para } K \ge 0 \tag{3.17}$$

O fading de *Rayleigh*, que se caracteriza por rápidas e profundas variações do sinal que chega ao receptor, uma ocorrência típica de ambientes urbanos densos com altos níveis de espalhamento do sinal pode, como mostrado, ser tanto um caso particular do *fading* de *Rice* (K = 0) quanto do *fading* de *Nakagami-m* (m = 1).

O modelo *Nakagami-m* contorna as limitações do fator *K* do modelo de *Rice*, porém é um modelo desenvolvido sobre as bases da estatística clássica ou frequentista não sendo flexível o suficiente para aplicações em *Machine Learning* ou em aplicações voltadas a inteligência artificial.

4 CANAL FADING - O MODELO BAYESIANO

Neste capítulo serão analisados o teorema de *Bayes*, conceitos relacionados e os mecanismos de análise e suas particularidades envolvidos na construção de um processo *bayesiano*.

4.1 O TEOREMA DE BAYES

Sempre que uma afirmação sobre a probabilidade P(A) de um evento A é dada, ela é dada implicitamente condicionada a outros fatores conhecidos. Desta forma, qualquer afirmação sobre probabilidades é uma afirmação condicionada ao que é conhecido. Esses tipos de probabilidades são chamados de probabilidades condicionais e geralmente são declarações do seguinte tipo: "Dado o evento B, a probabilidade do evento A é p", ou P(A|B) = p.

Deve ser enfatizado que P(A|B) = p não significa que sempre que B for verdadeiro a probabilidade de A é p mas que se B for verdadeiro e todo o resto for irrelevante para A, então a probabilidade de A é p.

Supondo que sejam atribuídas probabilidades a todos os subconjuntos do espaço amostral S, e sejam A e B subconjuntos de S. A questão é se a atribuição de probabilidade para S pode ser usada para calcular P(A|B). Se o evento B for conhecido, então todos os resultados possíveis são elementos de B, e os resultados para os quais A pode ser verdadeiro são $A \cap B$. Assim, procura-se a atribuição de probabilidade para $A \cap B$ dado que B é conhecido. Conhecer B não altera a proporção entre as probabilidades de $A \cap B$ e outro conjunto $C \cap B$. Conclui-se que as proporções $P(A \cap B)/P(C \cap B)$ e $P(A|B)/P(C \cap B)$ devem ser iguais. Definindo C = B, e sabendo que P(A|B) = 1, justifica-se a seguinte propriedade, que deve ser considerada um axioma.

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \tag{4.01}$$

Ao se tratar com probabilidades condicionais, é possível condicionar múltiplos eventos. Nesses casos, a definição de probabilidade condicional torna-se mais geral:

$$P(A|B \cap C) = \frac{P(A \cap B \cap C)}{P(B \cap C)} \tag{4.02}$$

A partir de (4.01) pode-se escrever:

$$P(A|B).P(B) = P(A \cap B)$$

que é a chamada regra fundamental do cálculo estatístico. Ou seja, a regra fundamental diz como calcular a probabilidade de A e B quando se conhece a probabilidade de A dado B e a probabilidade de B.

Condicionando outro evento C, a regra fundamental também pode ser escrita como:

$$P(A|B \cap C).P(B|C) = P(A \cap B|C)$$

Como $P(A \cap B) = P(B \cap A)$ e, também, $P(A \cap B | C) = P(B \cap A | C)$, obtém-se, da regra fundamental, que $P(A|B).P(B) = P(A \cap B) = P(B|A).P(A)$. Isso produz a regra ou Teorema de *Bayes*:

$$P(A|B) = \frac{P(B|A).P(A)}{P(B)}$$
(4.03)

sendo $P(B) = \sum_A P(B|A).P(A)$ a soma sobre todos os valores possíveis de A, ou para o caso de um valor contínuo de A $P(B) = \int P(B|A).P(A) dA$.

A regra de *Bayes* é um método para atualizar crenças sobre um evento A com base em informações que podem ser obtidas sobre outro evento B. A probabilidade de A antes de considerar B é chamada de probabilidade a priori (P(A)), enquanto a probabilidade de A dado B é chamado de probabilidade posterior (P(A|B)).

P(B|A) é a função de verossimilhança (*likelihood*) que apesar de ter o mesmo significado que probabilidade traz uma sutil diferença em análise estatística, descreve a probabilidade de observar dados que já foram coletados. Em uma definição mais específica: verossimilhança é a probabilidade de que um evento hipotético que já ocorreu produziria um resultado específico. A diferença de conceito está no fato de que probabilidade refere-se a eventos futuros e verossimilhança (*likelihood*) refere-se a eventos passados com resultados conhecidos (SAUNDERS 2008).

A partir da regra fundamental (4.01), também pode-se enunciar a regra de Bayes em relação a C:

$$P(A|B,C) = \frac{P(B|A,C).P(A|C)}{P(B|C)}$$

4.2 O PROCESSO DE OTIMIZAÇÃO ESTATÍSTICA

O teorema de *Bayes* é de fundamental importância em aplicações de inferência estatística e em muitos modelos avançados de *Machine Learning*. Busca, em sua essência, calcular a probabilidade de uma situação com base em sua relação com outro cenário, usa as informações disponíveis e incorpora probabilidades condicionais em conclusões.

A inferência *bayesiana* é uma abordagem lógica para atualizar o potencial de hipóteses à luz de novos conhecimentos, explica a probabilidade de um evento com base no conhecimento prévio das circunstâncias que podem ser relevantes para o evento (YOUSSEF 2022).

A otimização, quase sempre, é um processo difícil. Ao procurar um design ideal, gasta-se bastante e significativos recursos avaliando alternativas abaixo do ideal ao longo do caminho. Esta observação obriga a buscar métodos de otimização que, quando necessário, possam alocar cuidadosamente recursos para identificar parâmetros ideais da forma mais eficiente possível. Esse é o objetivo da otimização matemática.

Desde a década de 1960, as comunidades de estatística e aprendizado de máquina refinaram uma abordagem *bayesiana* para otimização. As rotinas de otimização contam com um modelo estatístico da função objetivo, cujas crenças orientam o algoritmo na tomada das decisões mais frutíferas. Esses modelos podem ser bastante sofisticados e mantê-los durante a otimização pode implicar custo significativo por si só. No entanto, a recompensa por este esforço é uma eficiência de amostra incomparável.

Por esta razão, a otimização *bayesiana* encontrou um nicho na otimização de objetivos que:

- São caros para calcular, impedindo uma avaliação exaustiva,
- Carecem de uma expressão útil, fazendo com que funcionem como "caixas pretas".
- Não podem ser avaliados com exatidão, mas apenas através de alguma ação indireta ou por mecanismos ruidosos.
 - Não oferecem nenhum mecanismo eficiente para estimar o seu gradiente.

Algoritmos de otimização *bayesiana* oferecem desempenho impressionante mesmo ao otimizar complexas "caixas pretas" sob condições de observação

severamente limitados. A otimização *bayesiana* provou ser bem-sucedida em ambientes que abrangem ciência, engenharia, economia, biologia e muito mais, incluindo ajustes de hiperparâmetros (TURNER et al. 2021).

4.3 O ENFOQUE BAYESINO

A otimização bayesiana não é um algoritmo específico, mas sim uma abordagem filosófica de otimização baseada na inferência bayesiana. Uma ampla gama de algoritmos foi derivada desta abordagem, que embora diversos em seus detalhes, compartilham alguns temas comuns em seu design.

Fundamentalmente, a otimização é uma sequência de decisões, onde em cada iteração decide-se onde fazer a próxima observação. Como os resultados destas decisões são regidos pelo sistema em estudo e estão fora do controle no processo, a eficácia da otimização depende inteiramente de uma boa tomada de decisão, o que se torna um desafio, especialmente quando feita em circunstâncias incertas. Uma política eficaz exige que se aborde esta incerteza.

A abordagem bayesiana é uma metodologia que se baseia na probabilidade e na inferência bayesiana para raciocinar sobre quantidades incertas que surgem durante a otimização. Trata a própria função objetivo como uma variável aleatória a ser inferida à luz das expectativas anteriores e de quaisquer dados disponíveis. Na otimização bayesiana, essa crença assume um papel ativo na tomada de decisões e orienta a política de otimização.

A principal motivação para a utilização dos fundamentos *bayesianos* é a facilidade de uma interpretação do senso comum de conclusões estatísticas. Ou seja, um intervalo de probabilidade *bayesiano* para uma quantidade desconhecida de interesse pode ser diretamente considerado como tendo uma alta probabilidade de conter a quantidade conhecida ao contrário do que ocorre num intervalo sob análise frequentista, o qual pode ser interpretado em relação apenas a uma sequência de inferências semelhantes que possam ser feitas e repetidas na prática.

Numa visão moderna, nas aplicações de modelos estatísticos, passou-se a dar maior ênfase na estimativa de intervalos em vez de testes de hipóteses, o que torna indispensável a utilização de técnicas *bayesianas* que permitem estimativas de intervalos de confiança padrão sob interpretação de senso comum.

4.3.1 A modelagem bayesiana

Um modelo é a representação de um sistema, gerado pela composição de conceitos que ajudam a conhecer, entender ou simular o objeto ou processo que o modelo representa. São representações projetadas com um objetivo particular e específico. Geralmente, é mais conveniente falar sobre a adequação do modelo a um determinado problema do que suas correções intrínsecas. Os modelos existem como uma ajuda para um objetivo adicional (HAMADE et al. 2018)

Esse princípio, é altamente relevante na modelagem *bayesiana*. Construir um modelo requer uma combinação de experiência, de domínio e habilidade sobre o sistema a ser modelado a fim de conhecer e determinar a utilidade do resultado.

Os modelos *bayesianos*, computacionais ou não, apresentam duas grandes características:

- Quantidades desconhecidas s\u00e3o descritas usando distribui\u00f3\u00f3es de probabilidade. Esse \u00e0 o par\u00e1metro de quantidade.
- O teorema de Bayes é usado para atualizar os valores dos parâmetros condicionados aos dados. Este processo pode ser visto como uma realocação de probabilidades.

O processo de construção de um modelo *bayesiano* pode ser escrito em 3 etapas:

- Tendo alguns dados e algumas suposições sobre como esses dados poderiam ter sido gerados, projeta-se um modelo combinando e transformando variáveis aleatórias.
- Utiliza-se o modelo de Bayes para condicionar o modelo aos dados disponíveis. Isto é chamado inferência de processo, e como resultado, obtém-se uma distribuição posterior. Neste ponto, espera-se que os dados reduzam a incerteza para possíveis valores de parâmetros.
- Analisa-se o modelo verificando se ele faz sentido de acordo com diferentes critérios, baseando principalmente no conhecimento, experiência e domínio do tema tratado. Também, é usual comparar diversos modelos (GARNETT 2022).

4.3.2 Inferência bayesiana

Inferência é um termo associado a obtenção de conclusões baseadas em evidência e raciocínio, é uma estrutura para inferir características incertas de um sistema de interesse a partir de observações baseadas nas leis da probabilidade.

Na abordagem *bayesiana* de inferência, todas as quantidades desconhecidas são tratadas como variáveis aleatórias. Esta é uma convenção poderosa, pois permite representar crenças sobre essas quantidades com distribuições de probabilidade refletindo seus valores plausíveis. A inferência assume então a forma de uma processo indutivo onde essas crenças são refinadas iterativamente à luz de dados observados utilizando leis de probabilidades.

Como acontece com qualquer indução, deve-se começar em algum lugar. Aqui, começa com uma chamada distribuição a priori (ou anterior) $p(\phi \mid x)$, que codifica o que consideramos valores plausíveis para ϕ antes de observar quaisquer dados. A distribuição anterior permite injetar conhecimento e experiência com o sistema de interesse no processo inferencial, poupando de ter que começar "do zero" ou considerar possibilidades patentemente absurdas.

Uma vez estabelecida uma priorização, o próximo estágio de inferência é refinar as crenças iniciais de acordo com os dados observados. Suponha que se faça uma observação da função objetivo em x, revelando uma medida y. Neste modelo de otimização, assume-se que a distribuição desta medida é determinada pelo valor de interesse ϕ através do modelo de observação $p(y \mid x, \phi)$. No contexto da inferência bayesiana, uma distribuição que explica os valores observados (y) em termos dos valores de interesse (ϕ) é conhecida como função de verossimilhança ou simplesmente verossimilhança.

Finalmente, dado o valor observado y, pode-se derivar a distribuição posterior atualizada (ou simplesmente posterior) de ϕ recorrendo ao teorema de Bayes:

$$p(\phi|x,y) = \frac{p(y|x,\phi).p(\phi|x)}{p(y|x)}$$

O posterior é proporcional ao anterior ponderado pela probabilidade do valor observado. O denominador é uma constante em ordem a ϕ que garante a normalização:

$$p(y|x) = \int p(y|x,\phi). p(\phi|x) d\phi$$

Conforme mencionado anteriormente, a inferência bayesiana é um processo indutivo pelo qual podemos continuar a refinar as nossas crenças através de observações adicionais. Neste ponto, a indução é trivial: para incorporar uma nova observação, o que era o nosso posterior serve como o anterior no contexto da nova informação, e multiplicar pela probabilidade e renormalizar produz um novo posterior. Podemos continuar desta maneira conforme desejado. A distribuição preditiva posterior incorpora naturalmente a incerteza no valor desconhecido da função objetivo.

O fluxograma da FIGURA 10 mostra a sequência lógica e iterativa de cálculos realizada num processo bayesiano.

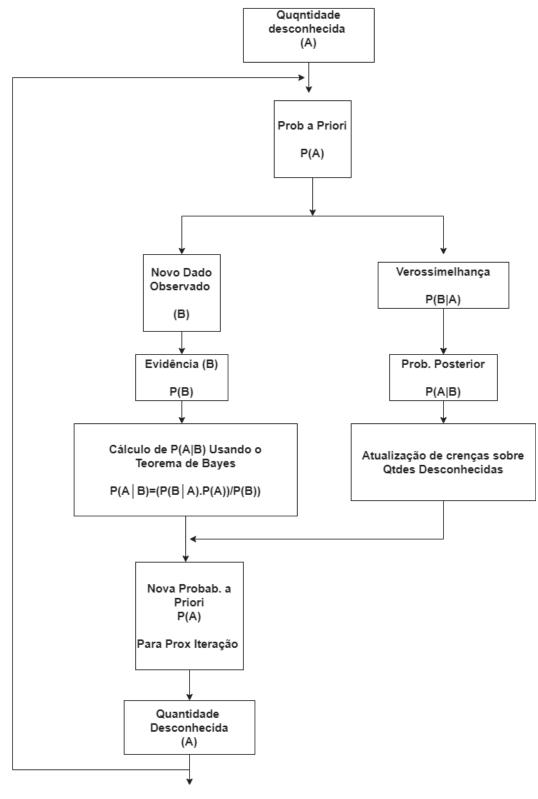


FIGURA 10 - LUXOGRAMA SEQUÊNCIA DE CALCULOS

Fonte: O autor (2023)

5 DEMONSTRAÇÕES, SIMULAÇÕES E RESULTADOS

Neste capítulo, com base na teoria exposta nos capítulos 3 e 4, é desenvolvido o modelo matemático e serão apresentados os resultados obtidos por simulação no MATLAB, TensorFlow e R Studio.

5.1 FUNDAMENTAÇÃO

5.1.1 Função Gama e Gama incompleta

Em matemática a função Gama é representada por $\Gamma(z)$ e é uma extensão da função fatorial com seu argumento deslocado para baixo pelo fator 1 para reais ou números complexos. Ou seja, se n é inteiro positivo:

$$\Gamma(n) = (n-1)!$$

É definida para todos os números complexos com parte real positiva, é dada por:

$$\Gamma(z) = \int_0^\infty t^{z-1} e^{-t} dt \tag{5.1}$$

A função Gama é importante em matemática pura e aplicada, faz parte de várias distribuições de probabilidade, também é utilizada para calcular a função densidade de probabilidade e função de distribuição acumulada da distribuição Gama, descreve dados positivamente assimétricos.

A função Gama incompleta $\gamma(z)$ é uma variação da função Gama definida por uma integral com limite superior finito.

$$\gamma(z) = \int_0^t t^{z-1} e^{-t} dt$$

A função Gama incompleta também é indefinida quando a variável é igual a um número inteiro negativo ou zero.

5.1.2 Distribuição Gama

É uma distribuição de probabilidade contínua que descreve a ocorrência de eventos ao longo do tempo ou do espaço.

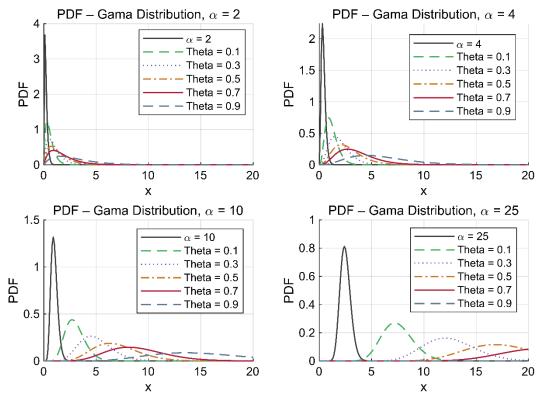
A Função Densidade de Probabilidade (FDP) é dada por:

$$f(x;\alpha,\theta) = \frac{1}{\theta^{\alpha}\Gamma(\alpha)} \cdot x^{\alpha-1} \cdot e^{\frac{-x}{\theta}}$$
 (5.2)

onde: α = Parâmetro de forma ($\alpha > 0$)

 θ = Parâmetro de escala ($\theta > 0$)

FIGURA 11 - COMPORTAMENTO DA DIST GAMA PARA DIVERSOS VALORES DE lpha E heta



Fonte: O autor (2022)

5.1.3 Distribuição Normal

A distribuição normal descreve com grande precisão fenômenos naturais e está ligada a importantes fenômenos físicos como o movimento browniano e o ruído branco. Sua FDP é dada por:

$$f(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$
 (5.3)

Onde: μ = Média

 σ = Desvio padrão

 σ^2 = Variância

5.2 APLICAÇÃO DO TEOREMA DE BAYES

No caso em análise, a distribuição Normal será a distribuição a priori, fato que será devidamente demostrado e validado pelas simulações de acordo com as Fig. 18 e 19. Além disso um processo *gaussiano* é representado pela média e por uma função de covariância. A média (μ) afeta apenas a distribuição marginal dos valores da função enquanto a função de covariância pode modificar a distribuição conjunta dos valores da função mantendo as características *gaussianas* do processo.

A escolha distribuição Gama como distribuição posterior, pode ser justificada por diversos fatores:

- A distribuição Gama, base do modelo de *Nakagami*, possui parâmetros de forma e escala (α, θ), FIGURA 11, que permitem flexibilidade no ajuste e análise do modelo.
- Em simulações comparativas com outras distribuições (Weibull, Log-Normal, Poisson...) foi a que retornou os melhores resultados simulados.

A escolha da função Gama também é devidamente demonstrada e validada nas simulações, FIGURA 19.

A função de covariância é uma medida estatística na qual é possível comparar duas variáveis permitindo entender como elas se relacionam entre si.

De acordo com as justificativas apresentadas, e tendo a distribuição Gama como a distribuição a posteriori, aplicando ao teorema de Bayes:

$$p(A|B) = \frac{P(B|A) * P(A)}{P(B)} \qquad \Rightarrow \qquad p(X|Y) = \frac{P(Y|X) * P(X)}{P(Y)}$$

$$p(X|Y) = \frac{\left(\frac{1}{\Gamma(\alpha)\theta^{\alpha}} \cdot Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}}\right) \cdot \left(\frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}}\right)}{\int \left(\frac{1}{\Gamma(\alpha)\theta^{\alpha}} \cdot Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}}\right) \cdot \left(\frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}}\right) dXdY}$$
(5.4)

O denominador da fórmula do Teorema de Bayes, é a probabilidade marginal de X, que envolve a integração sobre todos os valores possíveis de Y, pois X é a variável observada e Y é a variável sobre a qual estamos atualizando nossa crença.

Então, (5.4) é a expressão da FDP normalizada da distribuição resultante, considerando a distribuição Normal como distribuição a priori e a distribuição Gama como a posteriori. Simplificando:

$$p(X|Y) = \frac{Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X - \mu)^2}{2\sigma^2}}}{\int Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X - \mu)^2}{2\sigma^2}} dY}$$
(5.5)

A integral de normalização do denominador representa o somatório das hipóteses possíveis e mutuamente excludentes e é, portanto, igual a:

$$\int Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}} dY$$

Resolvendo em relação a X, os termos que não dependem de X são constantes.

Considerando apenas o termo que contém o termo $e^{-\frac{(X-\mu)^2}{2\sigma^2}}$:

$$\int e^{-\frac{(X-\mu)^2}{2\sigma^2}} dX$$

Esta é a integral gaussiana da distribuição Normal, bastante conhecida:

$$\int e^{-\frac{(X-\mu)^2}{2\sigma^2}} dX = \sigma\sqrt{2\pi}$$
(5.6)

Resolvendo em relação a Y:

$$\int Y^{\alpha-1}.e^{-\frac{Y}{\theta}}.dY$$

A melhor solução para essa integral é usando a definição da função Gama:

$$\Gamma(\alpha) = \int_0^\infty t^{\alpha - 1} e^{-t} dt \tag{5.7}$$

Resolvendo por partes:

$$u = \frac{Y}{\theta}$$
 $Y = \theta u$ e $dY = \theta du$

Substituindo $Y \in dY$ na integral:

$$\int Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} dY = \int (\theta u)^{\alpha-1} \cdot e^{-u} \cdot \theta du$$

Simplificando:

$$\int Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} dY = \theta^{\alpha} \int u^{\alpha-1} \cdot e^{-u} du$$

O integrando é a definição da função Gama (5.7)

$$\theta^{\alpha} \int u^{\alpha-1} \cdot e^{-u} du = \theta^{\alpha} \cdot \Gamma(\alpha)$$

Substituindo na integral original:

$$\int Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} dY = \theta^{\alpha} \cdot \Gamma(\alpha)$$
 (5.8)

Substituindo em (5.5) e simplificando:

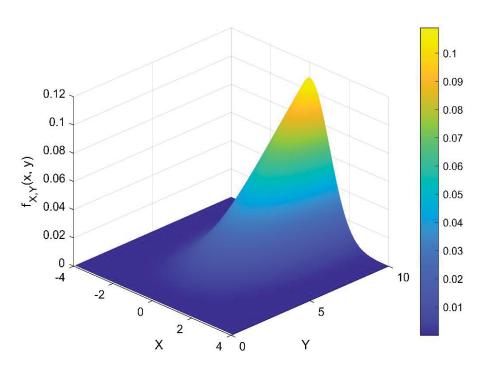
$$p(Y|X) = \frac{Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}}}{\sigma\sqrt{2\pi} \cdot \theta^{\alpha} \cdot \Gamma(\alpha)}$$
(5.9)

A expressão 5.9 é a PDF da distribuição resultante considerando a distribuição Normal como a distribuição a priori e a distribuição Gama como a função de verossimilhança (Likelihood). A esta distribuição resultante será chamada de Distribuição Ele (\mathcal{L}), portanto:

$$\mathcal{L}(Y,\alpha,\theta) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} Y^{\alpha-1} e^{-\left(\frac{Y}{\theta} + \frac{(X-\mu)^2}{2\sigma^2}\right)}$$
 (5.10)

A FIGURA 12 mostra a superfície da FDP conjunta da distribuição $\mathcal{L} f(x, y)$.

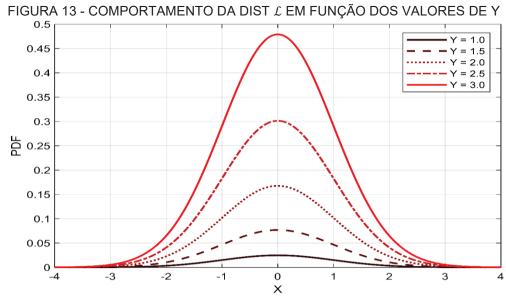
FIGURA 12 - SUPERFICIE DA PDF CONJUNTA f(x, y)



Fonte: O autor (2023)

As curvas apresentadas na FIGURA 13 são seções da função densidade de probabilidade conjunta $f_{X,Y}(x,y)$ para valores fixos de Y. Cada curva corresponde à avaliação da PDF conjunta ao longo de x, mantendo y constante. Como se trata de

fatias da distribuição conjunta, e não de PDFs condicionais, as áreas sob as curvas não são unitárias — refletindo a variação da densidade marginal de Y (distribuição Gama). A integral total sobre x e y é igual a 1, conforme exigido para uma PDF conjunta.



Fonte: O autor (2023)

A variável na distribuição posterior é *Y*. No cálculo da PDF, cada termo na distribuição anterior, distribuição Normal, é multiplicado pelo termo correspondente na distribuição posterior. Ao variar o valor de *Y*, avalia-se essencialmente como a distribuição posterior afeta e é afetada pela distribuição anterior e, consequentemente, como ela afeta o formato da PDF resultante.

A variável Y pode representar qualquer parâmetro, seja uma função, vetor ou distribuição. Essa variável pode abranger uma quantidade física ou um parâmetro que influencia a propagação, como a potência de um sinal recebido. A flexibilidade de Y permite uma análise abrangente de vários fatores que impactam o comportamento do sinal.

5.2.1 Análise da normalização da distribuição $\mathcal L$

Para verificar a correta normalização da expressão da distribuição \mathcal{L} (5.10) é necessário integrá-la em relação a X e Y:

$$\mathcal{L}(Y,\alpha,\theta) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)}.Y^{\alpha-1}e^{-\left(\frac{Y}{\theta}+\frac{(X-\mu)^2}{2\sigma^2}\right)}$$

 Integrando em relação a Y de 0 a ∞, analisando a parte que depende de Y:

$$\int_0^\infty Y^{\alpha-1}.e^{-\frac{Y}{\theta}}dY$$

Essa integral é a definição da função Gama:

$$\int_0^\infty Y^{\alpha-1}.e^{-\frac{Y}{\theta}}dY = \theta^{\alpha}\Gamma(\alpha)$$

• Integrando em relação a *X* considerando a parte que depende de *X*:

$$\int_{-\infty}^{\infty} e^{-\frac{(X-\mu)^2}{2\sigma^2}}$$

Esta é a integral da distribuição Normal não normalizada:

$$\int_{-\infty}^{\infty} e^{-\frac{(X-\mu)^2}{2\sigma^2}} = \sigma\sqrt{2\pi}$$

Combinando a solução das duas integrais e substituindo na expressão de £:

$$\mathcal{L}(Y,\alpha,\theta) = \frac{1}{\sqrt{2\pi}\sigma\theta^{\alpha}\Gamma(\alpha)}.Y^{\alpha-1}e^{-\left(\frac{Y}{\theta} + \frac{(X-\mu)^2}{2\sigma^2}\right)} = \frac{1}{\sqrt{2\pi}\sigma\theta^{\alpha}\Gamma(\alpha)}.\theta^{\alpha}\Gamma(\alpha).\sigma\sqrt{2\pi}$$

Simplificando:

$$\mathcal{L}(X,\alpha,\theta)=1$$

5.2.2 Análise da expressão da FDP

Ao analisar o termo Y na equação 5.10 deve-se atentar a dois valores principais possíveis: Y = 1 e $Y \to \infty$.

5.2.2.1 Quando Y = 1

Fazendo Y=1, o termo $Y^{\alpha-1}$ se torna $Y^{\alpha-1}=1^{\alpha-1}=1$, ou seja, este termo será sempre independentemente do valor da α .

O termo $e^{-\frac{Y}{\theta}}$ se torna $e^{-\frac{1}{\theta}}$, isto é, depende do valor de θ , que pode ter as seguintes posições:

- Se $\theta>0$ O termo $e^{-\frac{1}{\theta}}$ será sempre maior que zero e menor ou igual a 1, isto porque o termo exponencial resultará em um número positivo cujo valor diminuí à medida que θ aumenta.
- Se $\theta=0$, então o termo $e^{-\frac{1}{\theta}}$ não está definido pois envolve divisão por zero.
- Se $\theta < 0$, o termo $e^{-\frac{1}{\theta}}$ não está definido, pois envolve exponenciação de um número negativo.

Porém, por definição da distribuição Gama, θ necessariamente tem que ser maior que zero ($\theta > 0$).

5.2.2.2 Quando $Y \rightarrow \infty$

Se Y assume um valor muito grande o termo $Y^{\alpha-1}$ se torna dominante pois no limite tem-se para o termo $e^{-\frac{Y}{\theta}}$:

$$\lim_{Y \to \infty} e^{-\frac{Y}{\theta}} = e^{\lim_{Y \to \infty} -\frac{Y}{\theta}}$$

Pode-se observar que o limite da exponencial é uma função decrescente no numerador e constante no denominador, então o limite do termo exponencial será zero, e:

$$\lim_{Y\to\infty}e^{-\frac{Y}{\theta}}=e^0=1$$

Pode-se, portanto, simplificar a expressão mantendo apenas o termo dominante:

$$p(X; Y \to \infty) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)}.Y^{\alpha-1}$$

No caso da análise em questão $Y \to \infty$ é uma situação improvável ou impossível, pois está se falando de uma variável da distribuição Gama.

A distribuição Gama é uma distribuição contínua de probabilidade definida para valores reais positivos. Em termos matemáticos, isso é frequentemente expresso como o intervalo (0,∞). Este intervalo significa que a variável aleatória pode assumir qualquer valor maior que zero, mas não inclui o infinito como um valor real que a variável pode assumir. Em outras palavras, não existe um limite superior finito fixo para os valores que a variável pode tomar, mas todos os valores reais que ela assume são finitos. Portanto, "variável infinita" para a distribuição Gama não se refere a valores infinitos da variável aleatória em si, mas pode se referir ao comportamento assintótico de características como média ou variância sob certas condições dos parâmetros da distribuição (Ross 2010).

5.2.3 Função de Distribuição Acumulada

Para determinar a FDA, partindo da FDP da distribuição \mathcal{L} (5.10) para um intervalo de tempo de 0 a t:

$$F(D) = \int_0^t \mathcal{L}(Y; \alpha, \theta) dY$$
 (5.11)

Substituindo em (5.12):

$$F(D) = \int_0^t \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}} dY$$

A integral resultante é complexa para ser resolvida analiticamente, sua solução exige métodos numéricos próprios para a distribuição Gama e Normal.

A integração de $Y^{\alpha-1}$. $e^{-\frac{Y}{\theta}}$ de 0 a t é uma integral da função Gama incompleta:

$$\gamma(\alpha,t) = \int_0^t t^{\alpha-1} e^{-t} dt$$

Fazendo a substituição:

$$t = \frac{Y}{\theta} \qquad \Longrightarrow \quad Y = \theta t \qquad \Longrightarrow \quad dY = \theta dt$$

$$F(D) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \int_{0}^{\frac{t}{\theta}} \theta^{\alpha}t^{\alpha-1}e^{-t}\theta dt$$

$$F(D) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot \theta^{\alpha}\theta \int_{0}^{\frac{t}{\theta}} t^{\alpha-1}e^{-t}dt$$

$$F(D) = \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot \theta^{\alpha+1} \int_{0}^{\frac{t}{\theta}} t^{\alpha-1}e^{-t}dt$$

$$F(D) = \frac{\sqrt{2\pi} \cdot \theta^{\alpha+1}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot \gamma\left(\alpha, \frac{t}{\theta}\right)$$

O termo $e^{-\frac{(X-\mu)^2}{2\sigma^2}}$ é uma constante em relação a integração em Y e permanece na expressão. Então a FDA fica:

$$F(D) = \frac{\sqrt{2\pi} \cdot \theta}{2\pi\sigma\Gamma(\alpha)} \gamma\left(\alpha, \frac{t}{\theta}\right) \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}}$$
 (5.12)

Por efeitos de simplificação, uma análise permite concluir que na expressão da F(D), X é a variável conhecida originária da distribuição a *priori* (Normal). Numa

próxima iteração p(X|Y) se tornará a distribuição a priori, também conhecida, e como será provado continua a ter distribuição Normal.

Para o caso de X ser uma variável aleatória e de distribuição desconhecida para incorporar a incerteza em X na análise então uma integração em relação a X se torna necessária, considerando a distribuição conjunta de X e Y.

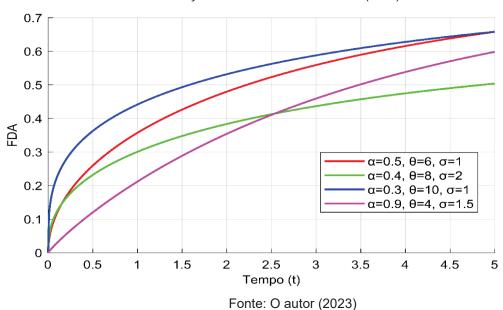


FIGURA 14 - FUNÇÃO DISTRIB ACUMULADA (FDA) DISTB $\mathcal L$

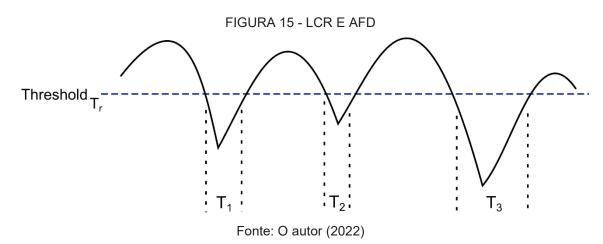
5.2.4 Considerações gerais da análise

A inferência *bayesiana* é um processo indutivo pelo qual podemos continuar a refinar uma crença por meio de observação adicional. Então a indução passa a ser um procedimento trivial, para incorporar uma nova observação, que no caso era a observação a posteriori, esta passa a ser a observação a priori e multiplicando pela probabilidade renormalizada produz uma nova posteriori. O processo se repete até que seja encontrado um ponto que atenda o objetivo.

5.3 DETERMINAÇÃO DOS PARÂMETROS ESTATÍSTICOS DO FADING

O Level Crossing Rate (LCR) e o Average Fade Duration (AFD) descrevem como o canal de comunicação varia no tempo são parâmetros estatísticos de segunda ordem, fundamentais para definição da qualidade do sinal recebido. O AFD é especialmente crítico na compreensão das estatísticas de erro do sinal.

O LCR para um threshold especificado é definido como a taxa esperada na qual a envoltória do sinal recebido cruza esse nível, em uma direção positiva ou negativa. O AFD é o período médio para o qual o envelope do sinal no receptor está abaixo do limite de threshold (T_r) .



Em cenários realistas (ambientes urbanos densos, suburbanos, áreas rurais...) a taxa de desvanecimento e a amplitude da envoltória do sinal são função do tempo. Para projetos de redes sem fio torna-se importante obter o nível quantitativo da taxa na qual ocorrem os desvanecimentos em qualquer profundidade e, também, a média do tempo de duração. Estes parâmetros são uteis para o projeto de diversos protocolos de codificação em redes digitais sem fio.

5.3.1 Cálculo do LCR

Para o cálculo do LCR é proposto um conceito de probabilidade relacionado a processos estocásticos chamado Long-Run Rate (LRR). Calcula a taxa de ocorrência de longo prazo (Long-Run Rate) de um evento em um processo estocástico, dividindo o valor esperado do número total de eventos pelo tempo total, e considerando esse cálculo no limite quando o tempo se aproxima do infinito. Essa expressão é típica em qualquer contexto em que se analisa a frequência de eventos ao longo do tempo em um sistema estocástico. Porém não é um método usual na literatura para o cálculo do LCR.

A partir da FDP da distribuição pode-se calcular o LCR. Definindo limite de amplitude (T_r) que é o nível de interesse em contar a taxa de cruzamentos:

$$LCR = \lim_{T \to \infty} (1/T) * E[N(t)]$$

onde t é o intervalo de tempo, (1/T) é a média normalizada pelo tempo e E[N(t)] é a expectativa ou valor esperado do número de vezes que o nível de threshold é cruzado até o tempo t.

$$E[N(t)] = \int_0^\infty f(X) * (1 - F(X - T_r)) dX$$

sendo f(X) a função densidade de probabilidade (FDP) e $F(X-T_r)$ a função de distribuição acumulada (CDR) avaliada em $X-T_r$.

Substituindo na equação 5.8:

$$E[N(t)] = \int_0^\infty \mathcal{L}(Y; \alpha, \theta) \cdot \left(1 - F(X - T_r)\right) dX$$

$$E[N(t)] = \int_0^\infty \frac{\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)\theta^{\alpha}} \cdot Y^{\alpha - 1} \cdot e^{-\left[\frac{Y}{\theta} + \frac{(X - \mu)^2}{2\sigma^2}\right]} \cdot \left(1 - F(X - T_r)\right) dX$$

$$E[N(t)] = \frac{\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)\theta^{\alpha}} \cdot \int_0^\infty Y^{\alpha - 1} \cdot e^{-\left[\frac{Y}{\theta} + \frac{(X - \mu)^2}{2\sigma^2}\right]} \cdot \left(1 - F(X - T_r)\right) dX$$

Isolando a variável Y:

$$E[N(t)] = \frac{\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)\theta^{\alpha}} \cdot \int_0^{\infty} Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} \cdot e^{-\frac{(X-\mu)^2}{2\sigma^2}} \cdot \left(\int_{-\infty}^{x-T_r} e^{-\frac{(X-\mu)^2}{2\sigma^2}} \cdot dX\right) dY$$

Resolvendo em relação a X utilizando a distribuição normal:

$$E[N(t)] = \frac{\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)\theta^{\alpha}} \cdot \int_{0}^{\infty} Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} \left(\Phi\left(\frac{X - T_r - \mu}{\sigma}\right)\right) dY$$

onde Φ é a função de distribuição acumulada (CDF) da distribuição normal.

Resolvendo em relação a Y, utilizando propriedade da função Gama:

$$\int_0^\infty Y^{\alpha-1} \cdot e^{-\frac{Y}{\theta}} dY = \theta^{\alpha} \cdot \Gamma(\alpha)$$

Simplificando:

$$E[N(t)] = \frac{\sqrt{2\pi}}{2\pi\sigma} \int_0^\infty \Phi\left(\frac{X - T_r - \mu}{\sigma}\right) dY = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \left[Y \cdot \Phi\left(\frac{X - T_r - \mu}{\sigma}\right)\right]_0^\infty$$

Com $Y \to \infty$, o limite superior da integral tende a 0

$$E[N(t)] = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \lim_{Y \to \infty} Y \cdot \Phi\left(\frac{X - T_r - \mu}{\sigma}\right) - 0$$

Substituindo em (5.8):

$$LCR = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \lim_{t \to \infty} \frac{1}{T} \cdot \int_0^\infty \left(1 - \Phi\left(\frac{X - T_r - \mu}{\sigma}\right) \right) \cdot Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} dY$$
 (5.13)

Na Equação (5.13), o $\lim_{T\to\infty}$ indica que está se considerando o comportamento do LCR quando se observa a taxa de cruzamento do nível T_r por um período longo, para um período determinado t têm-se:

$$LCR(t) = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \frac{1}{t} \int_0^t \left(1 - \Phi\left(\frac{X - T_r - \mu}{\sigma}\right) \right) \cdot Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} dY$$
 (5.14)

sendo que Φ é a função de densidade acumulada da distribuição Normal e, neste contexto, calcula a probabilidade de o sinal assumir determinado valor abaixo do nível T_r , isto é, está relacionada ao cálculo da probabilidade de ultrapassagem do limite de threshold.

Para o caso específico de um link móvel onde deve ser considerado o efeito Doppler, considerando o desvio de frequência Doppler ($\Delta f = 2vf/c$):

Substituindo no argumento da CDF da distribuição Normal Φ:

$$\Phi\left(\frac{X-T_r-\mu}{\sigma}\right) = \Phi\left(\frac{X-T_r-\mu}{\sigma+\frac{\Delta f.c}{2f}}\right) = \Phi\left(\frac{X-T_r-\mu}{\sigma+\frac{(2vf)}{c}}\right)$$

Finalmente, substituindo em (5.16):

$$LCR(t) = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \frac{1}{t} \int_0^t \left(1 - \Phi\left(\frac{X - T_r - \mu}{\sigma + \frac{(2vf)}{c}}\right) \right) \cdot Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} dY$$
 (5.15)

Esta é a expressão do LCR que incorpora o efeito Doppler através da velocidade relativa v.

A solução desta equação pode ser desafiadora devido à natureza da função envolvida, especialmente a CDF (Cumulative Distribution Function) Φ da distribuição Normal. Algumas formas de possíveis soluções seriam:

a. Solução analítica:

a.1. Simplificação com valores específicos: Atribuindo valores para $\alpha, \theta, \sigma, v, f$, d e c a integral será consideravelmente simplificada. A função Φ pode ser avaliada numericamente e a integral se torna "mais gerenciável".

- a.2. *Aproximações*: Em algumas situações, especialmente se σ e $\frac{(2vf)}{c}$ são pequenos em comparação a $(X T_r \mu)$ pode ser possível usar aproximações para a função Φ .
- b. Solução numérica: Esta é certamente a abordagem mais prática para integrais mais complexas como esta, especialmente no contexto de engenharia e ciências aplicadas.
 - b.1. Métodos numéricos como a regra do trapézio, *Simpson*, ou métodos de integração numérica adaptativos disponíveis em *softwares* científicos: Matlab, *Python*, R, *Wolfram*...
 - b.2. Simulações: Simular o processo estocástico para diferentes valores de t e calcular o LCR com base em simulações pode trazer insights valiosos. Principalmente se o interesse for entender o comportamento do LCR sob diferentes condições de movimento e variações do sinal.

5.3.2 Cálculo do AFD

O Average Fade Duration (AFD) é uma medida estatística que representa a média das durações de todos os eventos de desvanecimento em um determinado intervalo de tempo. É calculado como a média aritmética das durações de todos os desvanecimentos que ocorrem durante um determinado período. Fornece uma estimativa da duração média dos desvanecimentos e é usado para caracterizar a propagação do sinal em um canal de comunicação.

A compreensão do *AFD* é fundamental no projeto e dimensionamento de sistemas wireless, principalmente em utilizações sensíveis ao tempo como transmissão de áudio e vídeo em tempo real.

Supondo que se tenha um conjunto de durações de desvanecimentos $\{D_1, D_2, ..., D_N\}$ onde N é o número total de desvanecimentos observados. O AFD pode ser calculado como:

$$AFD = \frac{1}{N} \cdot \sum D_i$$

Ou, tendo a FDP da distribuição de probabilidades e integrando a FDA multiplicada pela duração de cada evento, tem-se:

$$AFD = \int_0^\infty D.F(D)dD \tag{5.16}$$

onde F(D) é a função de distribuição acumulada da distribuição e D é a variável de interesse.

$$AFD = \frac{\theta\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)} \cdot \int_0^t D \cdot \left(\gamma(\alpha, D/\theta) e^{-\frac{(X-\mu)^2}{2\sigma^2}}\right) dD$$
 (5.17)

Resolvendo em relação a X:

$$\int_0^\infty e^{-\frac{(X-\mu)^2}{2\sigma^2}} dX = \sigma\sqrt{2\pi}$$

Resolvendo em relação a Y:

$$\int_0^t D.\gamma(\alpha, D/\theta) dD$$

A solução desta integral é um tanto desafiadora devido a presença da função Gama incompleta γ . Não há uma forma fechada para a solução, geralmente requer métodos computacionais ou técnicas específicas para a função Gama. Pode, numa abordagem analítica, se buscar uma solução aproximada ou simplificação sob certas condições.

A função Gama incompleta é dada por: $\gamma(\alpha, x) = \int_0^x t^{\alpha-1} e^{-t} dt$.

Ao derivar $\gamma(\alpha, D/\theta)$ em relação a θ usa-se a regra da cadeia (a derivada de uma função composta é o produto das derivadas), sendo $\gamma'(\alpha, x)$ a derivada da função Gama incompleta em relação ao argumento x (D/θ):

Seja $g(\theta) = D/\theta$ então:

$$\frac{dg}{d\theta} = \frac{d}{d\theta} \left(\frac{D}{\theta} \right) = -\frac{D}{\theta^2}$$

Então, para $\gamma(\alpha, g(\theta))$ a derivada em relação a θ é:

$$\frac{d}{d\theta}\gamma\left(\alpha, \frac{D}{\theta}\right) = \gamma'\left(\alpha, \frac{D}{\theta}\right) \cdot \frac{dg}{d\theta}$$

$$\frac{d}{d\theta}\gamma\left(\alpha, \frac{D}{\theta}\right) = \gamma'\left(\alpha, \frac{D}{\theta}\right) \cdot \left(-\frac{D}{\theta^2}\right)$$

Substituindo na integral:

$$\int_{0}^{t} D.\gamma(\alpha, D/\theta) dD = \int_{0}^{t} D.\left(-\frac{D}{\theta^{2}}\gamma'\left(\alpha, \frac{D}{\theta}\right)\right) dD$$

$$\int_{0}^{t} D.\gamma(\alpha, \frac{D}{\theta}) dD = -\frac{1}{\theta^{2}} \int_{0}^{t} D^{2} \gamma'(\alpha, \frac{D}{\theta}) dD$$

Substituindo em (5.19):

$$AFD = \frac{\theta\sqrt{2\pi}}{2\pi\sigma\Gamma(\alpha)} \cdot \sigma\sqrt{2\pi} \cdot \left(-\frac{1}{\theta^2} \int_0^t D^2 \gamma'\left(\alpha, \frac{D}{\theta}\right) dD\right)$$

E finalmente:

$$AFD = -\frac{\theta}{\Gamma(\alpha)} \cdot \int_0^t D^2 \gamma' \left(\alpha, \frac{D}{\theta}\right) dD \tag{5.18}$$

D é uma variável de integração, e seu significado depende do contexto específico da função de distribuição que está sendo utilizada. D pode representar uma magnitude de sinal ou um parâmetro relacionado à intensidade do sinal. É uma variável de integração que varia de 0 a t. O significado exato de D depende da formulação da distribuição \mathcal{L} . Se \mathcal{L} é uma distribuição que descreve a variação da intensidade do sinal, então D seria uma representação dessa intensidade ou um parâmetro relacionado. O sinal negativo indica que a contagem de tempo é feita tomando os cruzamentos de nível do sinal de baixo para cima do nível de threshold.

5.4 TAXA BER - BIT ERROR RATE

5.4.1 Taxa BER causada pelo ruido gaussiano branco (AWGN)

A taxa BER é dada por:

$$BER = \frac{1}{2} \cdot Q\left(\sqrt{\frac{E_b}{N_0}}\right)$$

onde Q é a função de erro complementar da distribuição normal, E_b é a energia por bit e N_0 a densidade espectral de potência do ruído.

$$Q(x) = \frac{1}{2}.erfc\left(\frac{x}{\sqrt{2}}\right)$$

A função de erro complementar descreve a probabilidade de que uma variável aleatória normal padrão esteja acima de um determinado valor. Em outras palavras, a

erf c fornece a probabilidade de que uma variável com distribuição Normal padrão esteja em um intervalo específico ou além de um determinado valor.

Sendo erfc a função complementar de erro erfc(x) = 1 - erf(x) e erf é a função de erro definida como:

$$er f(x) = \frac{2}{\sqrt{\pi}} \cdot \int_0^x e^{-t^2} dt$$

Do ponto de vista estocástico, para determinar o parâmetro BER utiliza-se a seguinte expressão (Andrews et al. 2001):

$$BER = \frac{1}{2} \cdot \int_{0}^{\infty} p(x) erfc\left(\frac{SNR}{2\sqrt{2}} \cdot x\right) dx$$

onde p(x) é a FDP e erfc é a função de erro da distribuição normal.

Usando a FDP da distribuição \mathcal{L} (5.12):

$$BER = \frac{1}{2} \cdot \int_{0}^{\infty} \frac{\sqrt{2\pi}}{2\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot Y^{\alpha-1} e^{-\left[\frac{Y}{\theta} + \frac{(X-\mu)^{2}}{2\sigma^{2}}\right]} \cdot erfc\left(\frac{SNR}{2\sqrt{2}} \cdot x\right) dX$$

Rearranjando:

$$BER = \frac{\sqrt{2\pi}}{4\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot \int_{0}^{\infty} Y^{\alpha-1}e^{-\frac{Y}{\theta}} \left(\int_{0}^{\infty} e^{-\frac{(X-\mu)^{2}}{2\sigma^{2}}} \cdot erfc\left(\frac{SNR}{2\sqrt{2}} \cdot x\right) dX \right) dY$$

$$\int_{0}^{\infty} e^{-\frac{(X-\mu)^{2}}{2\sigma^{2}}} \cdot erfc\left(\frac{SNR}{2\sqrt{2}} \cdot x\right) dX$$

Resolvendo utilizando a propriedade da função de erro complementar:

$$\int_0^\infty e^{-\frac{(X-\mu)^2}{2\sigma^2}} \cdot erfc\left(\frac{SNR}{2\sqrt{2}} \cdot x\right) dX =$$

Fazendo:
$$u = \frac{X - \mu}{\sigma \sqrt{2}}$$
 $\implies du = \frac{1}{\sigma \sqrt{2}}$ $\implies dx = \sigma \sqrt{2} du$

Substituindo:

$$\int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty} e^{-u^2} \cdot erfc\left(\frac{SNR}{2\sqrt{2}} \cdot \sigma\sqrt{2}u\right) \sigma\sqrt{2}du$$

Simplificando:

$$\sigma\sqrt{2}\int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty}e^{-u^2}\cdot erfc\left(\frac{SNR}{2\sqrt{2}}\cdot\sigma u\right)du$$

Usando a propriedade da função de erro complementar:

$$erfc(u) = 1 - erf(u)$$

$$\sigma\sqrt{2}\int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty}e^{-u^2}.(1-erf(SNR\sigma u))du$$

$$\sigma\sqrt{2}\left(\int_{-\infty}^{\infty}e^{-u^{2}}du-\int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty}e^{-u^{2}}rf(SNR\sigma u)du\right)$$

A primeira integral é a integral da densidade de probabilidade da distribuição Normal e é igual a $\sqrt{\pi}$.

$$\int_{-\infty}^{\infty} e^{-u^2} du = \int_{-\infty}^{\infty} e^{-au^2} du = \sqrt{\pi}$$

Conforme demonstrado em (5.8).

A segunda integral é a da função de erro na forma derivada em relação a u ou $2e^{-u^2}/\sqrt{\pi}$. Então:

$$\sigma\sqrt{2}\left(\sqrt{\pi}-\frac{2}{\sqrt{\pi}}\cdot\int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty}e^{-u^2}\cdot e^{-(SNR\sigma u)^2}du\right)$$

Simplificando:

$$\sigma\sqrt{2\pi} - \frac{2}{\sqrt{\pi}} \int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty} e^{-(1+SNR^2\sigma^2)u^2} du$$

Integrando o termo exponencial:

$$\sigma\sqrt{2\pi} - \frac{1}{\sqrt{1 + SNR^2\sigma^2}} \int_{-\frac{\mu}{\sigma\sqrt{2}}}^{\infty} \frac{1}{\sqrt{2\pi} \cdot \sqrt{1 + SNR^2\sigma^2}} e^{e^{-(1 + SNR^2\sigma^2)u^2}} d[(1 + SNR^2\sigma^2)u]$$

$$\sigma\sqrt{2\pi} - \frac{1}{\sqrt{1 + SNR^2\sigma^2}} \cdot \frac{1}{\sqrt{2\pi(1 + SNR^2\sigma^2)}} \cdot erf[(1 + SNR^2\sigma^2)u] - \frac{\mu}{\sigma\sqrt{2}}$$

Substituindo os limites:

$$\sigma\sqrt{2\pi} - \frac{1}{\sqrt{1 + SNR^2\sigma^2}} \left(\frac{1}{\sqrt{2\pi(1 + SNR^2\sigma^2)}}.0 - \frac{1}{\sqrt{2\pi(1 + SNR^2\sigma^2)}}.erf\left[(1 + SNR^2\sigma^2) \left(-\frac{\mu}{\sigma\sqrt{2}} \right) \right] \right)$$

Como o primeiro termo é igual a 0:

$$\sigma\sqrt{2\pi} + \frac{1}{\sqrt{2\pi(1 + SNR^2\sigma^2)}}erf\left[(1 + SNR^2\sigma^2)\left(\frac{\mu}{\sigma\sqrt{2}}\right)\right]$$

Como:

$$erfc(u) = 1 - erf(u)$$

$$erfc\left(\frac{\mu}{\sigma\sqrt{2}}\right) = 1 - erf\left(\frac{\mu}{\sigma\sqrt{2}}\right)$$

$$\frac{1}{2}erf\left(1 + SNR^2\sigma^2 \cdot \frac{\mu}{\sigma\sqrt{2}}\right)\left(1 - SNR^2\sigma^2 \cdot \frac{\mu}{\sigma\sqrt{2}}\right)$$

Rearranjando e simplificando, finalmente têm-se:

$$\int_{0}^{\infty} e^{-\frac{(X-\mu)^{2}}{2\sigma^{2}}} \cdot erfc\left(\frac{SNR}{2\sqrt{2}}.x\right) dX = \frac{1}{2} \cdot erfc\left(\frac{\sigma\mu}{\sigma^{2}\sqrt{2}} + \frac{SNR}{2\sigma\sqrt{2}}\right)$$

Substituindo na expressão do BER:

$$BER = \frac{\sqrt{2\pi}}{4\pi\sigma\theta^{\alpha}\Gamma(\alpha)} \cdot \int_{0}^{\infty} Y^{\alpha-1}e^{-\frac{Y}{\theta}} \cdot \frac{1}{2} \cdot erfc\left(\frac{\sigma\mu}{\sigma^{2}\sqrt{2}} + \frac{SNR}{2\sigma\sqrt{2}}\right) dY$$

Resolvendo em relação a Y:

$$\int_0^\infty Y^{\alpha-1} e^{-\frac{Y}{\theta}} dY = \theta^{\alpha} \Gamma(\alpha)$$

Finalmente:

$$BER = \frac{\sqrt{2\pi}}{8\pi\sigma} \cdot erfc\left(\frac{\sigma\mu}{\sigma^2\sqrt{2}} + \frac{SNR}{2\sigma\sqrt{2}}\right)$$
 (5.19)

5.5 RESPOSTA DO CANAL AO IMPULSO

A partir da distribuição de probabilidades (\mathcal{L}), equação 5.10, e determinado os parâmetros estatísticos do *fading* pode-se determinar a Resposta ao Impulso do canal de comunicação sob a ótica do efeito *fading*.

A resposta ao impulso descreve como o canal afeta um sinal transmitido, especialmente em termos de distorção e dispersão do sinal ao longo do tempo; mostra como um impulso (sinal muito curto e idealmente de largura infinitesimal) é alterado pelo canal.

Matematicamente, a resposta ao impulso é usualmente representada por h(t). O sinal x(t) passando por um canal com uma resposta h(t) tem como saída um sinal y(t) que é a convolução (*) de x(t) com h(t).

$$y(t) = x(t) * h(t)$$

A resposta ao impulso pode revelar vários efeitos do canal como atenuação, atraso, eco, multipercurso (reflexão), dispersão de frequência e efeito *fading*.

A compreensão da resposta ao impulso do canal permite projetar filtros, equalizadores e outras técnicas para compensar ou aproveitar as características do canal buscando qualidade e eficiência na comunicação.

0.9 0.9 0.0 0.7 0.0 0.0 0.0 0.0 0.1 0.2 0.3 0.4 0.5 Tempo (s)

FIGURA 16 - RESPOSTA AO IMPULSO DO CANAL SIMULADO AO LONGO DO TEMPO

Fonte: O autor (2023)

A FIGURA 15 mostra a simulação da resposta ao impulso do canal simulado a partir da distribuição \mathcal{L} (5.10). Tendo a resposta ao impulso e utilizando a transformada rápida de *Fourier* (FFT) e a transformada inversa de *Fourier* (IFFT), com o uso de técnicas de tratamento de sinais é possível reconstituir o sinal.

5.6 SIMULAÇÕES

Os parâmetros de simulação para cada modelo estão mostrados na TABELA 1.

TABELA 1 – PARÂMETROS DE SIMULAÇÃO DOS MODELOS.

Categoria	Parâmetros	Descrição	Valor
Parâmetros de Transmissão	Fs	frequência de Amostragem (Hz)	1e9
	f	Frequência do sinal (Hz)	7e6
	А	Amplitude do sinal	1
	N	Número de amostras	1000
	fc	Frequência da portadora (Hz)	38e9
	BW	Banda do canal (Hz)	100e6
Parâmetros modelo £	alpha	Parâmetro de forma da distribuição £	1
	theta	Parâmetro de escala da distribuição £	0.8
Parâmetros modelo Nakagami	m	Parâmetro da distribuição Nakagami	2.5
	Omega	Parâmetro de controle de Nakagami	6
parâmetros filtro particulado	Número de partículas	Número de partículas	500
	sigma	Desvio padrão	0.1

FONTE: O autor (2022)

O bit transmitido é representado por um pulso que tem duração de 0 a T_b , onde T_b é o tempo de duração do bit. Em um canal de comunicação o sinal ou cada bit transmitido está sujeito a ruídos de origem térmica dos equipamentos, ruídos devido a atmosfera, intermodulação, interações de origem eletromagnética etc. De forma geral, o efeito total pode ser simulado com a adição do ruído gaussiano branco AWGN ($Aditive\ White\ Gaussian\ Noise$) que será demodulado no receptor.

Uma típica amostra de fase de um sinal transmitido com o efeito do ruído é mostrada na FIGURA 17.

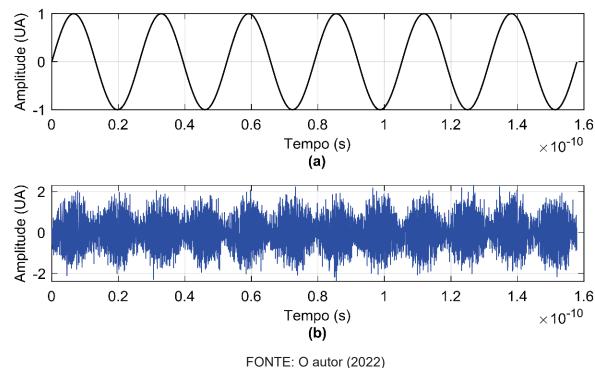


FIGURA 17 - (a) SINAL PURO TRANSMITIDO; (b) SINAL RECEBIDOO COM RUÍDO GAUSSIANO

TONTE. O autor (2022

Para efeitos de simulação usou-se a equação:

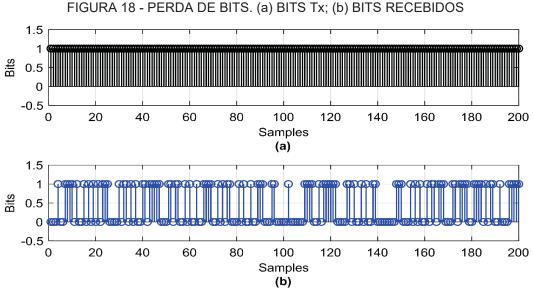
$$N_F = K_B T_0 B_W F (5.20)$$

onde B_w é a largura da banda do sinal e F é a figura de ruído no receptor que representa qualquer ruído adicional relativo ao ambiente leva em consideração os efeitos do meio ambiente (clima, ruído cósmico, chuva etc.) e aqueles gerados pelo homem (indústrias, motores, usinas de potência, subestações etc.). e é dada por:

$$F = 1 + \frac{T_e}{T_0} \tag{5.21}$$

sendo T_e a temperatura efetiva de 290°K (17°C).

Numa primeira análise de erros do sinal recebido (*BER – Bit Error Rate*) para um *stream* de *bits* transmitidos tem-se:



FONTE: O autor (2022)

Portanto, a primeira fonte de perdas no canal é o ruído branco (AWGN), inerente ao sistema.

5.6.1 Simulação e demonstração das distribuições.

Adicionando ruídos e simulando a distribuição de ruídos na recepção para um sinal senoidal transmitido com portadora de 38,0 GHz, modulação BPSK e considerando os efeitos de atenuação do espaço livre (500 m), ruído branco (AWGN), ruído atmosférico, absorção de vapor e efeito Doppler para o receptor com uma velocidade relativa de 60 km/h, tem-se:

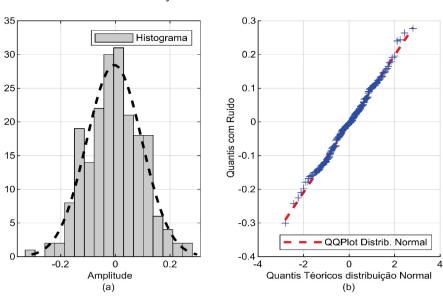


FIGURA 19 - DISTRIBUIÇÃO DE RUÍDOS/INTERFERÊNCIAS NO RX

FONTE: O autor (2023)

A FIGURA 18 (a) mostra, no receptor, a distribuição dos ruídos gerados na transmissão, o QQplot, FIGURA 18 (b) permite avaliar a distribuição dos pontos na distribuição, vê-se que os dados simulados aderem a distribuição Normal.

Em (5.10), Y pode representar uma função, vetor, quantidade física ou qualquer parâmetro que influencie a propagação, como a potência do sinal recebido ou a amplitude dos ruídos. Simulando as amplitudes da distribuição dos ruídos na recepção, da FDP da distribuição \mathcal{L} (5.10), as FIGURAS 19 (a) e (b) mostram que a distribuição das amplitude dos ruídos gerados no processo de transmissão (representando a variável Y) aderem a distribuição Gamma.

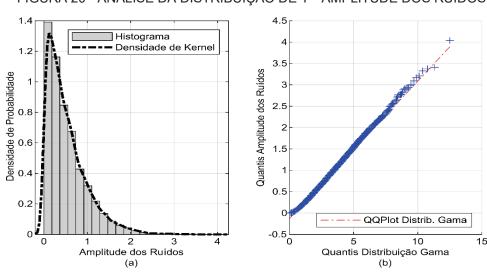


FIGURA 20 - ANÁLISE DA DISTRIBUIÇÃO DE Y - AMPLITUDE DOS RUÍDOS

FONTE: O autor (2023)

Fica, portanto, demonstrado que tanto a distribuição dos ruídos quanto das amplitudes, variável escolhida para representar Y, estão adequadamente usadas na da FDP da distribuição \mathcal{L} (5.10).

5.6.2 Simulação do LCR (Level Crossing Rate)

Apesar de, no espectro mmW, o sinal tender a se comportar como um sinal de luz praticamente não havendo reflexões e espalhamentos, medições relatadas em (GUAM et al. 2021) demonstram que mesmo no espectro mmW estruturas como edifícios, solo, outdoors, postes e vegetação podem efetivamente gerar componentes multipercurso, incluindo reflexões únicas, espalhamento e difração. Essas componentes variam rapidamente ao longo do tempo, e sua presença pode aumentar drasticamente o espalhamento angular.

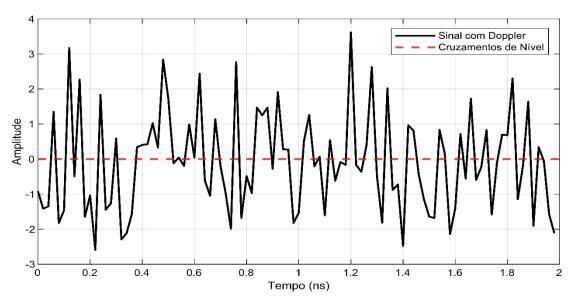
Assim, será incluído nas análises comparativas o modelo Rayleigh como um modelo teórico para efeitos de análise.

A partir de (5.15) aqui transcrita para facilidade de análise:

$$LCR(t) = \frac{\sqrt{2\pi}}{2\pi\sigma} \cdot \frac{1}{t} \int_0^t \left(1 - \Phi\left(\frac{X - T_r - \mu}{\sigma + \frac{(2vf)}{c}}\right) \right) \cdot Y^{\alpha - 1} \cdot e^{-\frac{Y}{\theta}} dY$$

A solução, por simulação, da expressão do LCR retorna:

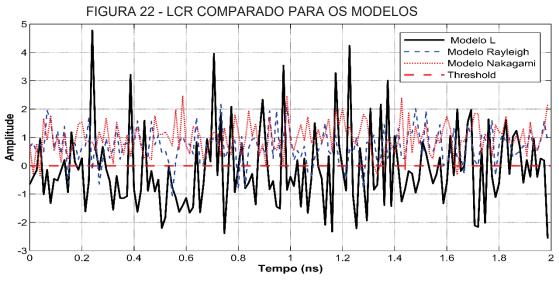
FIGURA 21 - SOLUÇÃO SIMULADA DA EXPRESSÃO DO LCR



FONTE: O autor (2023)

A FIGURA 22 mostra comparativamente o LCR para os modelos \mathcal{L} , Rayleigh e Nakagami. Pode se observar que o modelo proposto (\mathcal{L}) é mais apto a captar variações mais profundas de variações de amplitudes, ou seja, têm maior eficiência em captar amplitudes que levem a fadings mais rápidos e profundos.

- Modelo \mathcal{L} : Adequado para ambientes com alta variabilidade.
- Modelo Rayleigh: Representa canais com alta dispersão e muitos cruzamentos de nível, porém com menor amplitude que o modelo £.
- Modelo Nakagami: Menos suscetível a cruzamentos, ideal para canais estáveis com menor desvanecimento.



FONTE: O autor (2023)

O modelo £ proposto exibe maior dispersão em comparação aos modelos Rayleigh e Nakagami, demonstrando maior sensibilidade ao ruído. Isso permite uma representação mais realista de cenários com desvanecimento severo e variações complexas, tornando o modelo mais adequado para ambientes de propagação com interferência intensa, como aqueles esperados em comunicações de ondas milimétricas e áreas urbanas densas.

0.25 0.2 0.15 LCR 0.1 0.05 0 0 0.5 2.5 3 3.5 4.5 5 1.5 2 Tempo (s)

FIGURA 23 - DENSIDADE DE PROBABILIDADE DO LCR AO LONGO DO TEMPO

FONTE: O autor (2023)

A FIGURA 23 mostra como o LCR se comporta, dando uma visão dinâmica das transições do *fading*. A curva mostra o comportamento dinâmico do canal de

comunicação, ou seja, como interferências, movimento relativo do receptor (efeito *Doppler*), efeito de ruídos, etc. podem impactar o canal. Representa, em última análise, a flutuação do sinal.

O LCR está diretamente relacionado com a taxa de erro de bit (BER) o que também impacta o projeto do receptor, em canais com alto LCR, o receptor deve ser projetado para lidar com flutuações rápidas, equalizadores adaptativos e técnicas de diversidade (ex.: diversidade de tempo ou de frequência) podem ser necessários para combater o desvanecimento. Em canais com baixo LCR, o receptor pode ser simplificado, reduzindo o consumo de energia e a complexidade computacional.

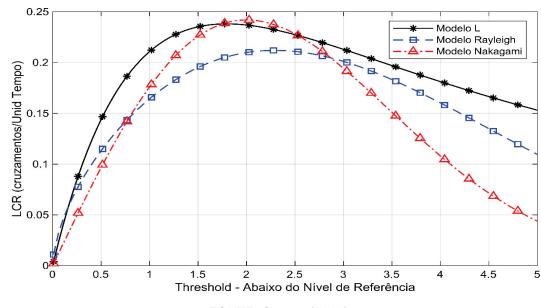


FIGURA 24 - COMPARATIVO TAXA DE CRUZAMENTOS \mathcal{L} x NAKAGAMI x RAYLEIGH

FONTE: O autor (2023)

A FIGURA 24 mostra comparativamente o número de cruzamentos de nivel para valoes abaixo do nivel do threshold para o modelo £ comparada ao modelo Nakagami e Rayleigh, fornecendo uma visão dinâmica do canal de comunicação, como ele é afetado por ruídos, interferências e efeito Doppler. Sabendo a frequência com que o sinal cruza determinado nível, é recomendável posicionar limiares de detecção próximos a esse valor, principalmente em valores críticos como valores de pico, ou aplicar técnicas de tolerância a erros mais robustas.

5.6.3 Simulação do AFD (Average Fade Duration)

O AFD simulado para o modelo \mathcal{L} a partir de (5.18) retorna a distribuição acumulada mostrada na FIGURA 25:

3.5 ··· Modelo L Threshold 3 2.5 1 0.5 O 0.2 0.3 0.6 0.7 8.0 0.9 Tempo (s) \times 10

FIGURA 25 - DISTRIBUIÇÃO ACUMULADA DURAÇÃO DOS FADES

FONTE: O autor (2023)

A curva de distribuição acumulada é uma ferramenta para entender e analisar a variabilidade da duração dos fades em um canal *wireless*, fornecendo uma visão sobre a confiabilidade e qualidade do sistema em diferentes condições.

- 1- Probabilidade de fades menor que determinado valor: Para cada ponto no eixo x (tempo) a probabilidade de um fade durar menos que esse tempo.
- 2- Tempo Médio Até o Próximo Fade: A inclinação da curva em um determinado ponto representa a densidade de probabilidade. Quanto mais inclinada a curva, maior é a probabilidade de ocorrência de um fade naquele intervalo de tempo.
 - 3- Comparação com Requisitos: Se houver requisitos específicos de qualidade do sinal para o sistema de comunicação, a curva de distribuição acumulada pode ser comparada a esses requisitos para avaliar o desempenho do sistema.

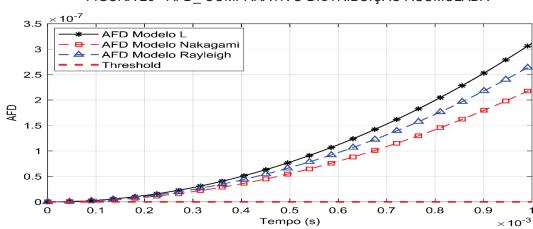
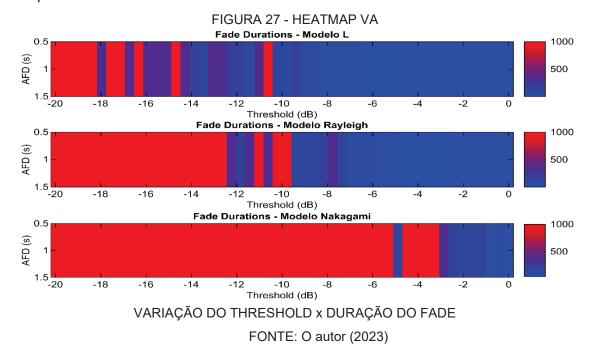


FIGURA 26 - AFD_ COMPARATIVO DISTRIBUIÇÃO ACUMULADA

FONTE: O autor (2023)

O modelo \mathcal{L} é o que apresenta maior tempo de duração dos fades devido à sua capacidade de capturar variações severas no sinal. Isso se reflete no gráfico com a curva de maior inclinação, o modelo Nakagami exibe menor duração dos fades, indicando que o canal é mais estável e menos suscetível a desvanecimentos prolongados devido a menor aptidão e sensibilidade do modelo em capturar variações de amplitude do sinal.



No mapa de calor, o eixo x mostra a variação do nivel de threshold, a cor indica a duração média dos fades para cada limite. Cores mais quentes (vermelho) indicam durações mais longas ou ausencia de sinal, enquanto cores mais frias (azul) indicam durações mais curtas.

Os mapas de calor permitem uma comparação direta de como diferentes modelos de desvanecimento reagem às variações no threshold, isto é útil para avaliar qual modelo pode ser mais adequado em simulações ou aplicações práticas específicas onde a duração dos fades é um fator crítico, como em sistemas de comunicação móvel.

Compreender as durações do desvanecimento ajuda a desenvolver protocolos de comunicação robustos em ambientes de desvanecimento variáveis. Por exemplo, sistemas que exigem alta confiabilidade, como comunicações de emergência, transmissões de áudio e vídeo em tempo real ou aplicações críticas, podem ser otimizados com base na duração esperada do desvanecimento para garantir que a troca de dados ocorra com menor risco de interrupção.

5.6.4 Simulação da taxa de bits perdidos (BER)

A simulação da expressão (5.19) da taxa BER para o modelo \mathcal{L} sob o efeito apenas do ruído Gaussiano branco retorna comparativamente ao valor teórico esperado:

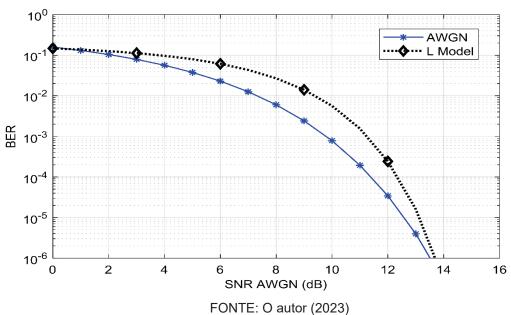


FIGURA 28 - COMP ENTRE A BER TEÓRICA E SIMULADA -AWGN- DA DISTRIBUIÇÃO $\mathcal{L}.$

Quando, na mesma condição de canal AWGN, se compara os modelos tem-se o resultado mostrado na FIGURA 29.

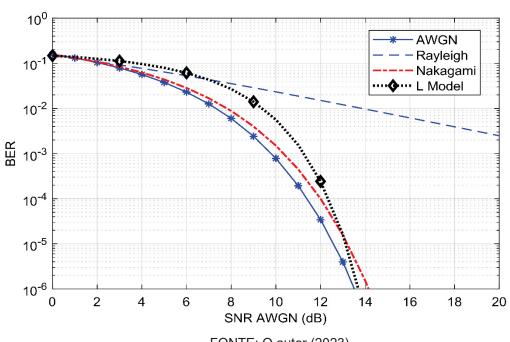


FIGURA 29 - COMPARATIVO BER AWGN

FONTE: O autor (2023)

O modelo Rayleigh, assume-se que não há linha de visão (LOS – Line-of-Sight) entre o transmissor e o receptor, e o sinal recebido é a soma de múltiplos sinais refletidos que chegam em fases aleatórias, o que resulta em uma curva de BER que começa a decair a partir de um ponto de SNR mais alto em comparação ao AWGN e mostra uma região de "piso" onde melhorias na SNR não reduzem significativamente o BER. mesmo com o aumento da Relação Sinal-Ruído (SNR), a BER (Bit Error Rate) não diminui significativamente e permanece em um nível relativamente constante. Isso significa que aumentar a potência do transmissor ou melhorar a eficiência do receptor não resultará em uma melhoria significativa na taxa de erro.

Adicionando os ruídos gerados na propagação, calculando a taxa de perdas e simulando o teórico *vs* calculado, obtém-se a curva da FIGURA 30.

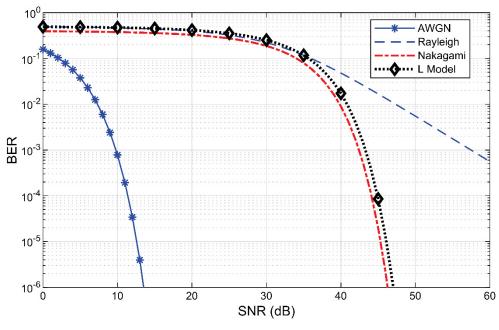


FIGURA 30 - BER COM ADIÇÃO DE RUÍDOS.

FONTE: O autor (2023)

A taxa BER ou Bit Error Rate é um parâmetro de fundamental importância e de grande eficiência para a simulação dos erros introduzidos pela soma dos diversos ruídos no canal, também é um parâmetro de grande relevância na análise da qualidade e eficiência do *link*, tornando-se uma ferramenta importante para auxiliar na busca de parâmetros que busquem garantir estabilidade e integridade do sinal entre transmissor e receptor. É um indicador ideal na análise do sistema, pois analisa o *link* na totalidade de sua extensão: transmissor, meio e receptor.

5.6.5 O sinal recebido

Completando o ciclo, tem-se o "fading channel power" (potência do canal fading) que se refere às variações estocásticas na potência do sinal à medida que ele se propaga por um meio como um canal sem fio. Essas variações acontecem devido a vários fatores ambientais e situacionais, como a distância entre o transmissor e o receptor, obstruções no caminho, condições atmosféricas e desvio Doppler. As flutuações de potência são medidas examinando as mudanças na amplitude do sinal recebido.

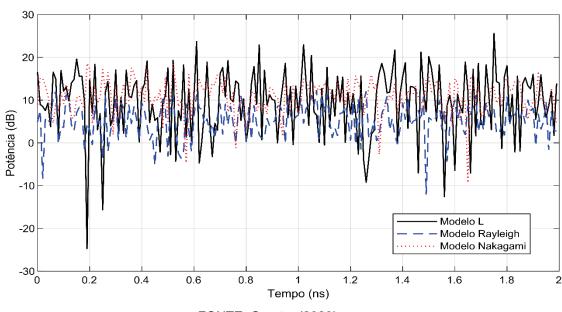


FIGURA 31 - COMPARATIVO POTÊNCIA DO SINAL RECEBIDO

FONTE: O autor (2023)

O gráfico da FIGURA 31 mostra, de forma comparada a potência do canal fade e ajuda a entender como diferentes modelos influenciam o comportamento do canal, principalmente a amplitude e a estabilidade do sinal na recepção.

O modelo \mathcal{L} proposto captura uma gama mais ampla de variações de amplitude acima e abaixo do *threshold*, o que permite caracterizar o desvanecimento rápido e profundo tipicamente observado em flutuações de sinal em frequências do espectro mmWave. Além disso, observa-se que o modelo Nakagami opera dentro de uma faixa mais estável, enquanto o modelo \mathcal{L} é sensível a níveis de potência ligeiramente mais altos do que o modelo Rayleigh.

5.6.6 Reconstruindo o sinal

Tendo completado o ciclo (transmissor, canal e receptor) e conhecendo o comportamento da variação da potência recebida para os modelos o sinal pode ser então reconstruído. Nesta fase da simulação o modelo Rayleigh não será comparado por não representar adequadamente o modelo de propagação no espectro mmW devido à arquitetura dos links (LOS) ou ao baixo ou inexistente espalhamento do sinal nesta banda do espectro.

Na reconstrução do sinal o canal será simulado por um filtro *FIR* (*Finite Impulse Response*) com largura de banda de 100 MHz (RECOMMENDATION ITU-R M.2083-0 _ IMT VISION - 2015), o sinal será reconstruído para os modelos $\mathcal L$ e Nakagami a fim de comparar a eficiência em mitigar dos efeitos do desvanecimento do canal.

A escolha do filtro *FIR* se deve às suas características fundamentais (CHANDRA; CHATTOPADHYAY - 2016):

- Estabilidade garantida: Os coeficientes dependem apenas das amostras de entrada.
- Fase linear: Pode ser implementado para ter uma resposta de fase linear; não distorce a forma de onda do sinal.
- Fácil implementação em hardware digital, pois não requer feedback.
- Flexibilidade no design: pode ser facilmente ajustado para atender a requisitos específicos de filtro, como passa-baixa, passa-alta e largura de banda.

Uma típica amostra de fase de um sinal transmitido com efeito de ruído, com base em (3.14) e (5.10), é mostrada na FIGURA 33.

Modelo L – Sinal Rx

| Sinal Tx | Signal Tx | Signa

FIGURA 32 - SINAL SENOIDAL PURO, SINAL RECEBIDO COM RUÍDOS: (a) MODELO \mathcal{L} , (b) NAKAGAMI

FONTE: O autor (2024)

A FIGURA 32, aqui repetida com o propósito de facilitar o entendimento da sequência da simulação, mostra um sinal senoidal puro transmitido e o sinal recebido com os ruídos gerados no canal e as variações de amplitudes para os modelos comparados. O modelo $\mathcal L$ proposto, como já visto, é sensível na captação de maiores amplitude do ruído. Em outras palavras, ele é mais sensível a variações de sinal rápidas e profundas típicas daquelas em ambientes urbanos e suburbanos densos.

A partir da distribuição de probabilidade do modelo Nakagami (3.14), do modelo \mathcal{L} (5.10) e da resposta do filtro FIR, é possível determinar a resposta ao impulso do canal sob a perspectiva do efeito de desvanecimento para cada modelo.

A resposta ao impulso descreve como o canal afeta um sinal transmitido, especialmente em termos de distorção e dispersão ao longo do tempo; mostra como o canal altera um impulso (um sinal muito curto, idealmente de largura infinitesimal).

Amplitude Normalizada L Impulse Response 0.2 0.4 0.6 0.8 1.2 1.4 1.6 1.8 Tempo (s) Amplitude Normalizada Nakagami Impulse Response 1 L 0.2 0.4 0.6 8.0 1.2 1.4 1.6 1.8 Tempo (s) $\times 10^{-7}$ FONTE: O autor (2024)

FIGURA 33 – RESPOSTA AO IMPULSO UNITÁRIO DO CANAL SIMULADA PARA UMA AMOSTRA NO PERÍODO.

Matematicamente, a resposta ao impulso é geralmente representada por h(t). O sinal x(t) que passa por um canal com uma resposta h(t) tem como saída um sinal y(t), que é a convolução (*) de x(t) com h(t).

$$y(t) = x(t) * h(t)$$

$$y(t) = x(t) * h(t) = \int_{-\infty}^{\infty} x(\tau) \cdot h(t - \tau) d\tau$$
 (5.22)

onde τ é um pulso no tempo (τ_i) . A resposta ao impulso h(t) descreve como o canal responde a um impulso unitário e a convolução de x(t) com h(t) nos dá a saída do canal para qualquer entrada x(t).

A resposta ao impulso pode revelar vários efeitos de canal, como atenuação, atraso, eco, multipercurso (reflexão), dispersão de frequência e desvanecimento. Entender a resposta ao impulso do canal permite o design de filtros, equalizadores e outras técnicas para compensar ou aproveitar as características do canal, buscando qualidade e eficiência na comunicação.

Tomando a resposta ao impulso e, usando a transformada rápida de Fourier (FFT) e a transformada inversa de *Fourier* (IFFT), e usando técnicas de processamento de sinal, o sinal pode ser reconstruído.

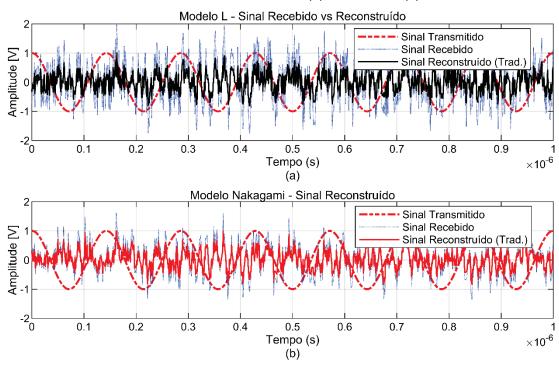


FIGURA 34 - SINAL RECONSTRUÍDO: (a) MODELO L, (b) NAKAGAMI

FONTE: O autor (2024)

A reconstrução do sinal adota o seguinte procedimento: a resposta ao impulso do canal h(t) no domínio do tempo é transformada para o domínio da frequência usando a Transformada de *Fourier*, resultando na função de transferência H(f).

A Transformada de *Fourier* de h(t) é:

$$H(f) = X(f) = \int_{-\infty}^{\infty} h(t) \cdot e^{-j2\pi f t} dt$$
 (5.23)

onde X(f) é o sinal de entrada x(t) transformado no domínio da frequência.

No domínio do tempo, a saída y(t) é a convolução do sinal de entrada x(t) com a resposta ao impulso h(t). A convolução no domínio do tempo corresponde à multiplicação no domínio da frequência. Portanto, no domínio da frequência, a saída Y(f) é:

$$Y(f) = X(f).H(f)$$

A saída no domínio do tempo é obtida aplicando a transformada inversa de Fourier Y(f):

$$Y(t) = \int_{-\infty}^{\infty} Y(f) \cdot e^{j2\pi ft} dt$$
 (5.24)

Outro método, mais comumente usado, consiste em usar a transformada rápida de *Fourier* (*FFT*) para calcular as transformadas de *Fourier* e a transformada rápida de *Fourier* inversa (*IFFT*) para retornar ao domínio do tempo. Dado h(t), pode-se calcular H(f) usando a *FFT*:

$$H(f) = FFT(h(t)) \tag{5.25}$$

Para determinar a FFT do sinal de entrada x(t), pode-se calcular X(f) usando o algoritmo FFT:

$$X(f) = FFT(x(t))$$

Para obter Y(f), multiplica-se X(f) por H(f), [Y(f)=X(f), H(f)] e aplica-se a *IFFT* a Y(f) para obter y(t):

$$y(t) = IFFT(Y(f))$$
 (5.26)

Usando este procedimento (FFT e IFFT), o processo de convolução é simplificado transformando-o para o domínio de frequência, onde a convolução se torna uma multiplicação simples; isso é computacionalmente eficiente e prático de implementar.

A FIGURA 34 mostra uma reconstrução comparativa do sinal mostrado na FIGURA 32. Para o modelo \mathcal{L} proposto, foram realizadas 3000 iterações (na FIGURA 34) para refinar o processo de reconstrução, e esta é uma das vantagens do modelo proposto, que, sendo construído sobre fundamentos bayesianos, permite este refinamento através de processos iterativos.

Pode-se observar que o modelo $\mathcal L$ é, por construção, menos conservador que o modelo Nakagami, ou seja, tem maior flexibilidade ao permitir que o sinal oscile em amplitudes maiores, capturando possíveis variações que possam causar o efeito fading. No entanto, tem maior uniformidade de resposta quando o sinal é reconstruído que o modelo Nakagami.

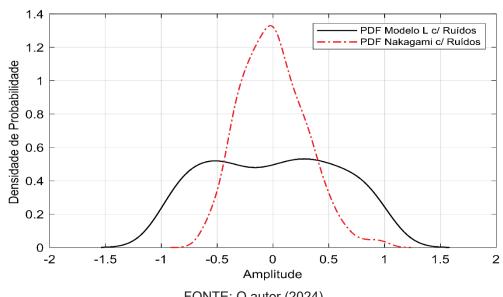


FIGURA 35 - PDFs DA DISTRIBUIÇÃO DE RUÍDOS DOS SINAIS RECONSTRUÍDOS

FONTE: O autor (2024)

A análise das "PDFs comparativas do ruído do sinal reconstruído", FIGURA 35, mostra que a distribuição Nakagami apresenta menor dispersão dos valores de ruído (base mais estreita); além disso, a maior densidade de probabilidade no centro (altura da curva) implica que a maioria dos valores de ruído para o sinal reconstruído estão concentrados perto do valor médio.

A base mais ampla da distribuição \mathcal{L} mostra maior dispersão de ruído, indicando uma variação mais ampla de valores em torno da média (maior variância). A menor altura da curva de densidade de probabilidade no centro implica que os valores são menos concentrados e mais distribuídos.

O modelo Nakagami, devido à sua menor dispersão de ruído, tende a resultar em um sinal mais estável e previsível, o que o torna vantajoso em ambientes onde a robustez contra variações de sinal é crítica. Como desvantagem, ele tem menos capacidade de se adaptar a variações rápidas e profundas de canal, tornando-o menos eficiente em ambientes de comunicação com muitas flutuações.

O modelo \mathcal{L} proposto, por sua vez, tem maior capacidade de representar variações e flutuações de canal, como as esperadas na propagação no espectro mmW, e pode se adaptar melhor a mudanças rápidas e significativas no ambiente de comunicação. Como desvantagem, a maior dispersão dos valores de ruído pode resultar em um sinal menos estável e mais suscetível a interferências.

Em resumo, com sua maior dispersão, o modelo \mathcal{L} pode representar uma variedade maior de cenários de ruído, o que é vantajoso em ambientes de comunicação altamente variáveis. A capacidade de lidar com flutuações severas torna o modelo adaptável a diferentes condições de canal, o que fornece robustez em ambientes imprevisíveis. O modelo é, portanto, vantajoso em cenários onde a adaptação a variações significativas nos níveis de ruído e interferência é necessária.

5.6.7 Reconstrução usando técnicas avançadas – Bayesianas

Um avanço significativo em técnicas de reconstrução de sinais pode ser alcançado usando filtros de partículas, também conhecidos como filtros particulados, filtros *bootstrap* ou métodos Monte Carlo Sequenciais. É um conjunto de algoritmos usado para estimar os estados internos de um sistema com base em observações parciais e ruidosas. Neste filtro, a inferência bayesiana permite estimar um estado combinado para uma medição com uma probabilidade prévia.

Os filtros de partículas não se aplicam apropriadamente ao modelo Nakagami ou qualquer outro derivado dos fundamentos da estatística clássica ou frequentista, pois são modelos estáticos que assumem uma distribuição específica para a magnitude do sinal de desvanecimento e, por natureza, não incorporam um mecanismo dinâmico para atualizar estados ou incorporar novas informações como os métodos bayesianos o fazem.

Por ser um algoritmo que permite a atualização contínua do estado dinâmico do sistema, o filtro de partículas pode rastrear variáveis que mudam ao longo do tempo, como o canal de comunicação.

5.6.7.1 Implementação

Na implementação do filtro de partículas, um conjunto de partículas (amostras) é usado para representar a distribuição posterior do estado do sistema. Cada partícula tem um peso que indica sua probabilidade.

$$\chi = \left\{ \left\langle x^{[j]}, \omega^{[j]} \right\rangle \right\}_{i=1,\dots,J} \tag{5.27}$$

Esta expressão (5.27) representa o conjunto de partículas (amostras) que o filtro usa para estimar o estado de um sistema dinâmico, onde $x^{[j]}$ é a j-ésima partícula, ou seja, uma possível amostra do estado atual ou uma representação hipotética do estado do sistema, e $\omega^{[j]}$ é o peso associado à j-ésima partícula. Ela representa a probabilidade relativa de que a partícula $x^{[j]}$ represente com precisão o verdadeiro estado do sistema. Pesos mais altos indicam que a partícula está mais alinhada com as observações atuais.

$$p(x) = \sum_{j=1}^{J} \omega^{[j]} \, \delta_{x^{[j]}}(x)$$
 (5.28)

Quanto mais partículas caírem em uma região, maior a probabilidade naquela região. Elas são inicializadas em torno do sinal recebido com ruído aleatório. Cada uma representa uma hipótese sobre o verdadeiro estado do sinal.

A cada iteração, as partículas são atualizadas com a adição de ruído e os pesos são ajustados de acordo com a probabilidade de observação atual, que mede a similaridade entre o sinal recebido e a amostra.

A reamostragem é feita para evitar a degeneração da amostra, onde poucas partículas assumem peso significativo. A reamostragem de acordo com o peso garante que partículas com peso maior (mais próximas do sinal verdadeiro) sejam selecionadas com mais frequência. A estimativa final do sinal é obtida como a média ponderada das partículas.

O filtro de partículas pode ser especialmente útil para lidar com incertezas e variações rápidas de sinal, fornecendo uma estimativa mais precisa do estado do sinal recebido.

Comparativamente, a reconstrução do sinal simulado para o modelo $\mathcal L$ usando técnicas tradicionais e filtros de partículas é mostrada na FIGURA 36:

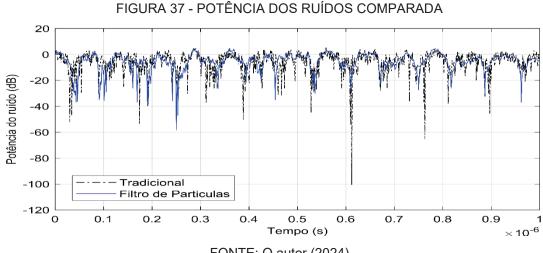
Modelo L - Reconstrução Tradicional Sinal Transmitido Sinal Recebido Amplitude [V] 0.2 0.9 0.3 0.5 0.6 0.7 8.0 Tempo (s) (a) - Reconstrução com Filtro Particulado Modelo L Transmitido Amplitude [V] 0.1 0.2 0.3 0.4 0.6 0.7 0.8 0.9 Tempo (s)

FIGURA 36 - SINAL RECONSTRUÍDO PARA O MODELO £ USANDO: (a) MÉTODO TRADICIONAL, (b) FILTRO PARTICULADO

FONTE: O autor (2024)

A filtragem bayesiana, sendo uma extensão natural do modelo \mathcal{L} proposto, facilita a integração metodológica e conceitual, permitindo uma abordagem coesa e robusta para entender o desvanecimento do canal e a reconstrução do sinal ao considerar a evolução temporal do estado do canal.

A FIGURA 37 compara as potências de ruído, mostra que o filtro de partículas apresenta menores variações ao longo do tempo, indicando maior eficiência de supressão de ruído do que o método tradicional. O filtro de partículas, portanto, tem maior capacidade de atenuar variações abruptas, resultando em uma reconstrução de sinal mais estável e precisa, reduzindo erros e melhorando o desempenho do sistema. Em aplicações práticas, os filtros de partículas podem resultar em um sinal reconstruído de maior qualidade, reduzindo erros e melhorando o desempenho do sistema de comunicação.



FONTE: O autor (2024)

Para facilidade de análise visual, o histograma da FIGURA 38 mostra a distribuição da potência de ruídos de forma comparativa entre os dois métodos. Cada barra do histograma mostra a frequência (ocorrência) relativa da potência do ruído (em dB) para cada método, permitindo uma comparação direta entre os dois métodos em termos de eficiência na redução do ruído.

0.35 Traditional Particle Filter 0.3 0.25 Probabilidade 0.2 0.15 0.1 0.05 0 -100 -40 -80 -60 -20 0 Potencia de Ruído (dB)

FIGURA 38 - HISTOGRAMA DA DISTRIBUIÇÃO DE RUÍDOS DO SINAL RECONSTRUÍDO

FONTE: O autor (2024)

Os valores de potência de ruído para o filtro particulado são menores e mais concentrados em torno de valores baixos, indicando que o ele consegue reduzir o ruído de forma mais eficaz. A maior concentração em um intervalo menor de valores de ruído sugere que o método é eficaz em manter a potência de ruído controlada, reduzindo variações extremas. A largura da distribuição de potência de ruído é um indicador importante; a distribuição mais estreita para o filtro particulado sugere consistência no desempenho do filtro na redução do ruído.

O método tradicional, com uma distribuição mais larga, implica flutuações maiores na potência de ruído, indicando que ele é menos eficaz e menos consistente na supressão do ruído.

-70 Tradicional Filtro de Particulas -80 Potência/Frequência (dB/Hz) -90 100 -110 -120 -130 0.5 1 1.5 2 2.5 3.5 4 4.5 5 $imes 10^8$ Frequência (Hz)

FIGURA 39 - DENSIDADE ESPECTRAL DE POTÊNCIA DO RUÍDO DO SINAL RECONSTRUÍDO (MODELO \mathcal{L})

FONTE: O autor (2024)

A Densidade Spectral de Potência (PSD), FIGURA 39, representa a quantidade de potência de ruído presente em cada Hertz (Hz) da largura de banda. Um valor de -120 dB indica uma potência de ruído muito baixa, aproximadamente 1,0 pW/Hz, enquanto um valor de -70 dB indica que a potência de ruído é de aproximadamente 100 pW/Hz.

O cálculo da Densidade Espectral de Potência (PSD) é baseado na frequência de amostragem e cobre a faixa de frequência de Nyquist (500 MHZ), que corresponde à metade da frequência de amostragem de 1,0 GHz. Para construir este indicador, a diferença entre o sinal transmitido e o sinal reconstruído na banda base após a remoção da portadora é analisada.

6 ANÁLISE E DISCUSSÃO DOS RESULTADOS

O modelo de *Rice* (3.12) é um modelo geral limitado pelo parâmetro *K* de *Rice*:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}} e^{-k} I_0\left(\frac{p}{\sigma}\sqrt{2k}\right)$$
(6.01)

O modelo de *Rayleigh* é derivado, sob determinadas condições (fazendo $I_0=1$ e K=0), o modelo *Rayleigh* e é aplicável a ambientes em que praticamente não há linha de visada direta e as componentes de espalhamento do sinal são predominantes:

$$FDP(p) = \frac{p}{\sigma^2} e^{-\frac{p^2}{2\sigma^2}}$$
 (6.02)

Este ambiente é tipicamente um meio urbano denso onde as variações de sinal ocorrem de maneira rápida e profunda.

Em princípio, dada as características de propagação do sinal em mmW, não faria muito sentido se falar em modelo Rayleigh nesta faixa de frequência, porém no trabalho de (Guan et al. 2021) onde medições na faixa de 28 GHz foram feitas ele diz: "Medições realizadas mostram que edifícios, solo, outdoors, postes e vegetação geram componentes multipercurso eficazes (reflexão única, dispersão, difração). Estas componentes de multipercurso são fortemente variantes no tempo e, em particular, os espalhamentos angulares aumentam dramaticamente na presença destas componentes." Então, faz sentido falar em modelo Rayleigh na faixa das mmW. Também, fica demonstrado que o modelo pode ser derivado a partir da distribuição $\mathcal L$ e é aplicável a outras faixas de frequência.

A distribuição de *Rayleigh* modela as variações de amplitude de um sinal no canal de comunicação predominantemente sem visada direta, a potência do sinal resultante é a soma dos quadrados das componentes de propagação. O valor da média da distribuição é dado pelo valor de pico do gráfico. À medida que *Y* se afasta da média, a probabilidade de ocorrência diminui, seguindo uma forma característica de sino.

As curvas da distribuição de Rayleigh e as da distribuição \mathcal{L} apresentam semelhanças na forma geral de sino. A cauda resultante da distribuição derivada de \mathcal{L} é mais longa que as da distribuição de Rayleigh, indicando dispersão

potencialmente maior ou decaimento mais lento na probabilidade de ocorrência à medida que *Y* se afasta da média.

FIGURA 40 - DISTRIB COMPARATIVA DA AMPLITUDE DO SINAL MODELO $\mathcal L$ vs RAYLEIGH

Fonte: O autor (2024)

A simulação na frequência de 38 GHz do sinal transmitido considerando os efeitos de ruídos tem-se o histograma da FIGURA 40 que mostra a distribuição das amplitudes do sinal para os modelos. Ambas as distribuições exibem características semelhantes na forma geral.

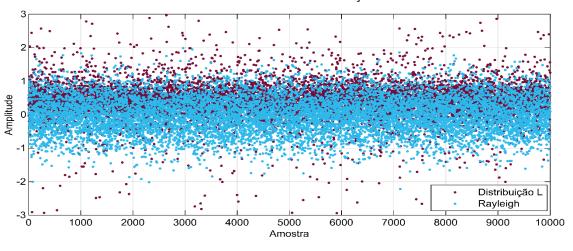


FIGURA 41 - - DISPERSÃO COMPARADA DA DISTRIBUIÇÃO DE AMPLITUDES

Fonte: O autor (2024)

O gráfico da FIGURA 41 permite visualizar a distribuição de amplitudes para ambas as distribuições ao longo das amostras.

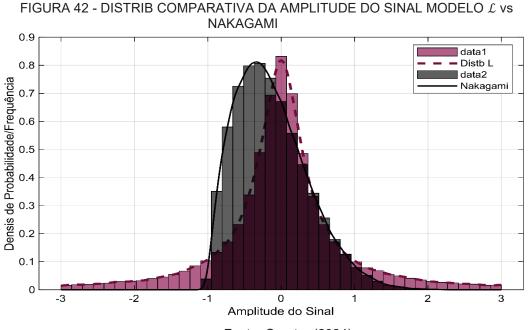
6.1 ANÁLISE COMPARATIVA ENTRE O MODELO $\mathcal L$ E O MODELO NAKAGAMI

O modelo *Nakagami* (3.14), embasado na estatística frequentista, contorna as limitações do fator *K* de *Rice*, é usado para descrever a variação rápida e não uniforme da amplitude de um sinal de comunicação sem fio devido ao espalhamento de multipercursos e em canais LOS. A principal característica do modelo Nakagami é que ele pode capturar uma ampla variedade de condições de propagação, desde cenários com grande dispersão (modelo *Rice*) até cenários com pouca dispersão. O modelo *Rayleigh* pode ser derivado a partir do modelo Nakagami, sendo um caso particular deste.

$$f(y; m, \Omega) = \frac{2m^m}{\Gamma(m)\Omega^m} y^{2m-1} e^{-\frac{m}{\Omega}y^2}$$

As distribuições \mathcal{L} e Nakagami têm alguma semelhança em suas expressões matemáticas, mas os fatores de normalização, os termos exponenciais e as potências de Y são diferentes, refletindo as características distintas dos modelos. A distribuição Nakagami tem uma forma mais simples, com uma potência par de Y, enquanto a distribuição \mathcal{L} é mais complexa, incorporando uma distribuição conjunta de uma distribuição gama e uma distribuição normal refletindo o caráter bayesiano.

Simulando o mesmo sinal transmitido na frequência de 38 GHz, tem-se mostrado na FIGURA 42 o histograma comparativo da geração de ruídos entre o modelo \mathcal{L} e o modelo Nakagami.



Fonte: O autor (2024)

O histograma mostra a distribuição da amplitude do sinal de acordo com cada um dos modelos comparados. Ambas as distribuições exibem características semelhantes na forma geral, porém a distribuição $\mathcal L$ tem maior flexibilidade de ajustes para diferentes condições de propagação visto que cobre uma faixa maior da distribuição de ruídos.

90 100 2000 3000 4000 5000 6000 7000 8000 9000 10000 Amostra

FIGURA 43 - DISPERSÃO COMPARADA DA DISTRIBUIÇÃO DE AMPLITUDES

Fonte: O autor (2023)

O gráfico da FIGURA 43 permite visualizar a distribuição de amplitudes para ambas as distribuições ao longo das amostras. O modelo Nakagami, limitado pelo ajuste do parâmetro de forma, tem uma maior estabilidade, ou seja, é menos flexível se comparado ao modelo \mathcal{L} .

6.2 CARACTERÍSTICAS DA ANÁLISE BAYESIANA

Comparativamente ao método estatístico frequentista, a análise Bayesiana tem uma série de características que a tornam vantajosa em análise de fenômenos variantes ao longo do tempo, como o canal de comunicação. Ao tratar quantidades desconhecidas como variáveis aleatórias, permite que essas quantidades sejam representadas por distribuições de probabilidade que refletem seus valores possíveis integrando conhecimento prévio com dados recentes observados e atualizando continuamente crenças sobre quantidades desconhecidas usando as leis da probabilidade:

a) Incorporação de Conhecimento Prévio

- Flexibilidade: Permite a incorporação de conhecimento prévio sobre o canal de comunicação, o que é especialmente útil quando se dispõe de dados históricos ou conhecimento especializado sobre o comportamento do canal sob certas condições.
- Atualização contínua: As crenças sobre o canal são continuamente atualizadas conforme novos dados são observados, tornando o modelo adaptável a mudanças no ambiente de comunicação.

b) Lidando com a incerteza

- Probabilidades Distribuídas: A abordagem Bayesiana lida explicitamente com a incerteza ao tratar quantidades desconhecidas como variáveis aleatórias, fornecendo uma representação mais completa e realista das variáveis de canal.
- Redução da Incerteza: A integração de novos dados reduz a incerteza nas previsões, melhorando a precisão das estimativas.

c) Melhor ajuste a dados complexos

- Estruturas de Dados Complexas: A abordagem Bayesiana é particularmente eficaz para lidar com estruturas de dados complexas e não lineares que são comuns em ambientes de comunicação de ondas milimétricas.
- Modelagem de Cenários Diversos: Esta técnica pode acomodar vários cenários de desvanecimento, fornecendo uma representação mais precisa do comportamento do sinal sob diferentes condições de propagação.

d) Aplicações em Aprendizado de Máquina

 Integração com IA e ML: A abordagem Bayesiana é compatível com métodos de inteligência artificial e aprendizado de máquina, permitindo a implementação de algoritmos adaptativos que melhoram a previsão e a mitigação dos efeitos de desvanecimento.

e) Avaliação Contínua de Desempenho

Métricas de desempenho: esse recurso permite a avaliação contínua de métricas de desempenho, como taxa de cruzamento de nível (LCR), duração média de desvanecimento (AFD) e taxa de erro de bit (BER), ajustando o modelo conforme necessário para manter o desempenho, a qualidade e a confiabilidade da comunicação.

Na comparação com métodos frequentistas:

- a) Métodos frequentistas: Tradicionalmente usam distribuições de probabilidade fixas e não atualizam continuamente as estimativas com novos dados. Essas abordagens são menos flexíveis e podem ser menos adaptáveis a mudanças rápidas no ambiente de comunicação.
- b) Limitações em mmW: Em frequências de ondas milimétricas, onde o comportamento do canal é altamente variável e sensível a mudanças ambientais, os métodos frequentistas podem não fornecer a precisão e a adaptabilidade necessárias para modelar o desvanecimento do canal de forma eficaz.

Em resumo, adotar a abordagem bayesiana oferece uma maneira mais flexível e robusta de modelar o desvanecimento do canal, especialmente em ambientes complexos e dinâmicos, como aqueles na faixa de ondas milimétricas. Ela supera as limitações dos métodos frequentistas ao lidar com incertezas e integrar continuamente novos dados.

6.3 POSSÍVEIS VANTAGENS DO MODELO £ PROPOSTO

Modelos de desvanecimento de canal aprimorados podem aumentar a confiabilidade e o desempenho da rede. Podemos extrair as seguintes implicações práticas das conclusões do estudo para a implementação de sistemas de comunicação mmW em ambientes do mundo real como áreas urbanas ou suburbanas.

6.3.1 Desafios em ambientes urbanos e suburbanos

Os sistemas de comunicação mmW enfrentam vários desafios em ambientes urbanos e suburbanos devido às características únicas de propagação dessas frequências. Alguns dos principais desafios incluem:

- a) Atenuação rápida: os sinais mmW sofrem atenuação rápida, limitando o alcance da transmissão e exigindo uma densidade maior de estações base.
- b) Baixa Penetração: Baixa capacidade de penetração através de obstáculos como paredes e edifícios reduzem a eficiência da cobertura externa e interna.
- c) Suscetibilidade à interferência: a interferência de elementos atmosféricos, como chuva e vapor de água afetam significativamente a qualidade do sinal.
- d) Dependência de LOS (Linha de Visão): A necessidade de links com visada direta (LOS) torna a comunicação mais suscetível a bloqueios físicos.

6.3.2 Melhorias esperadas do modelo proposto

O estudo propõe um modelo de desvanecimento de canal aprimorado com base em técnicas bayesianas com o propósito de mitigar alguns desses desafios. Implicações práticas e benefícios incluem:

a) Precisão e confiabilidade aprimoradas

- Modelagem precisa de desvanecimento: O modelo £ proposto pretende oferecer uma representação mais precisa do comportamento do fading em frequências mmW, considerando a variabilidade rápida e profunda do sinal.
- Integração de conhecimento prévio e dados observados: a abordagem bayesiana permite a atualização contínua de modelos com novos dados, melhorando a precisão e a confiabilidade ao longo do tempo.

b) Desempenho da rede

 Mitigação de interferência: modelos mais precisos permitem o desenvolvimento de estratégias de mitigação de interferência mais

- eficazes, melhorando a qualidade do sinal em ambientes urbanos e suburbanos.
- Otimização de recursos: a previsão precisa de desvanecimento ajuda a alocar recursos de forma eficiente, como potência de transmissão e seleção de canal, otimizando o desempenho da rede.
- Gerenciamento de interferência: a modelagem precisa ajuda a prever e gerenciar a interferência entre células adjacentes, aumentando a capacidade da rede de suportar mais usuários simultâneos.

c) Cobertura e capacidade

- Planejamento eficiente da rede: uma melhor compreensão dos padrões de desvanecimento permite um planejamento de infraestrutura de rede mais eficiente, como a colocação de estações base e repetidores.
- Capacidade de rede aprimorada: a redução de zonas de sombra e a melhoria da cobertura aumentam a capacidade da rede, suportando mais usuários simultaneamente.

d) Robustez e Estabilidade

- Redução dos fadings: modelos aprimorados ajudam a identificar e reduzir a frequência e a duração dos fadings, melhorando a estabilidade da conexão.
- Qualidade de Serviço (QoS): Melhorar a previsibilidade do desempenho do canal permite a implementação de esquemas de QoS mais robustos, garantindo um serviço consistente e de alta qualidade melhorando a experiência do usuário.

e) Integração com tecnologias avançadas

- Compatibilidade entre IA e ML: a abordagem bayesiana é compatível com algoritmos de inteligência artificial e aprendizado de máquina, permitindo o desenvolvimento de sistemas adaptativos que melhoram continuamente com a experiência.
- Suporte a dispositivos inteligentes: a precisão aprimorada do modelo beneficia dispositivos inteligentes que dependem de comunicação

confiável, como veículos autônomos e dispositivos de IoT em cidades inteligentes.

6.3.3 Melhorias em áreas urbanas

Redes, em geral, podem se beneficiar das características de técnicas avançadas de modelagem de fading, particularmente em ambientes urbanos densos e suburbanos nos seguintes fatores:

6.3.3.1 Áreas urbanas densas

a) Cobertura melhorada em ambientes densos

- Planejamento de Small cells: A maior precisão do modelo permite a otimização do posicionamento de small cells, o que é essencial em ambientes densamente povoados. Isso ajuda a garantir cobertura contínua e zonas de sombra reduzidas.
- Penetração em edifícios: modelos precisos podem ajudar a mitigar a baixa penetração de sinais mmW em edifícios, facilitando a implementação de soluções como femtocélulas e repetidores internos para melhorar a cobertura interna.

b) Aumento da capacidade da rede

- Gerenciamento de interferências: a modelagem precisa de desvanecimento ajuda a prever e gerenciar a interferência entre células adjacentes, aumentando a capacidade da rede de suportar mais usuários simultâneos.
- Utilização ideal do espectro: a previsão precisa das condições de desvanecimento permite uma alocação mais eficiente dos recursos do espectro, melhorando sua utilização.

c) Qualidade do Serviço (QoS)

- Estabilidade da conexão: modelos aprimorados ajudam a manter a estabilidade da conexão em áreas com alta variabilidade de sinal, como ruas estreitas e áreas com muitos obstáculos.
- Experiência do usuário aprimorada: reduzir a frequência e a duração dos fades melhora significativamente a experiência do usuário final em termos de velocidade e latência de dados.

6.3.3.2 Áreas suburbanas

a) Extensão da cobertura

- Alcance aprimorado: como as áreas suburbanas são menos densas, a maior distância entre as células exige modelagem precisa para maximizar o alcance de cada célula sem comprometer a qualidade do sinal.
- Mitigação de interferência ambiental: modelos aprimorados ajudam a mitigar a interferência causada pela vegetação e outras obstruções típicas de áreas suburbanas.

b) Eficiência energética

- Gerenciamento de potência de transmissão: a previsão precisa de desvanecimento permite ajustes dinâmicos na potência de transmissão, otimizando o consumo de energia das estações base e dos dispositivos do usuário.
- Uso eficiente do repetidor: modelos de desvanecimento precisos podem melhorar o uso eficiente de repetidores em áreas suburbanas, garantindo cobertura adequada em regiões de baixa densidade.

6.4 RECONSTRUÇÃO DO SINAL

A abordagem bayesiana, ao usar uma distribuição de probabilidade conjunta, permite que o modelo se adapte às condições do canal dinamicamente, fornecendo maior precisão de simulação e qualidade na reconstrução do sinal. O modelo $\mathcal L$ demonstrou vantagem ao fornecer maior uniformidade em comparação ao modelo Nakagami-m, a estrutura iterativa do modelo permite refinamentos sucessivos,

melhorando a precisão da estimativa do canal em cenários complexos e impactando diretamente a qualidade do sinal reconstruído.

Em conjunto com o filtro de partículas, o modelo \mathcal{L} demonstrou eficiência na captura de uma ampla gama de comportamentos de ruído, incluindo variações rápidas e profundas. Ele se adapta rapidamente às variações dinâmicas e ajusta efetivamente as partículas e pesos no filtro. A supressão de ruído é mais eficiente, resultando em sinais reconstruídos mais uniformes e com menores variações de ruído.

Como o modelo se baseia em princípios bayesianos, que exigem computações iterativas e trabalho com distribuições posteriores; técnicas como filtros de partículas, usadas para reconstrução de sinais, gerando e atualizando grande número de partículas em cada iteração o processo pode adicionar considerável demanda computacional geral. Isto sugere que o custo computacional não é trivial, especialmente para aplicações em tempo real. Implementar algoritmos de filtragem de partículas requer uma quantidade substancial de operações matemáticas para ajustar pesos e reamostrar partículas para cada novo conjunto de dados.

As simulações mostram que modelo proposto é eficaz para reconstrução de sinal e redução de ruído, porém sua dependência de processos iterativos e filtragem de partículas pode torná-lo desafiador para uso em sistemas que exijam tempos de resposta imediatos. A implementação em tempo real de filtros de partículas pode ser difícil, particularmente em ambientes com capacidades de processamento limitadas ou onde a baixa latência é crítica.

À medida que a tecnologia avança e o poder de processamento aumenta, juntamente com melhores técnicas de paralelização, o modelo pode encontrar uso em aplicações em tempo real, especialmente em redes adaptativas e inteligentes que podem tirar proveito de sua flexibilidade. No entanto, a implementação prática ainda pode exigir hardware de alto desempenho, especialmente em sistemas com requisitos de baixa latência. Algoritmos otimizados que podem reduzir a complexidade computacional sem comprometer a precisão também podem ajudar a reduzir as demandas computacionais.

7 CONCLUSÃO E ESTUDOS FUTUROS

Este trabalho comparou o modelo £ proposto com os modelos mais tradicionais para desvanecimento (*Rice, Rayleigh e Nakagami*). Essa escolha foi feita por serem esses os modelos dos quais as variantes de outros modelos frequentistas derivam; tudo permite que a análise seja estendida a todas as diferentes variantes dos modelos. O objetivo principal foi apresentar um modelo bayesiano mais flexível que facilite a conexão com algoritmos de IA e aprendizado de máquina que, alavancados pelo aumento da capacidade de processamento computacional ocorrido nos últimos anos, podem aumentar a eficiência e a confiabilidade das redes modernas.

Com o advento de redes sem fio e de dispositivos inteligentes modernos capazes de se reconfigurar conforme as demandas do ambiente, espera-se que os processos bayesianos ajudem a atingir eficiência e qualidade ideais em sistemas de comunicação; adotar a abordagem bayesiana oferece uma maneira mais flexível e robusta de modelar o desvanecimento do canal, especialmente em ambientes complexos e dinâmicos, como aqueles na faixa de ondas milimétricas. Ele supera as limitações dos métodos frequentistas ao lidar com incertezas e integrar continuamente novos dados.

Em geral, as redes podem se beneficiar do uso de técnicas avançadas de modelagem de desvanecimento, particularmente em ambientes urbanos densos, permitindo melhorias de cobertura ao planejar pequenas células para ajudar a garantir cobertura contínua e zonas de sombra reduzidas. Além disso, pode ajudar a mitigar a baixa penetração de sinal mmW em edifícios, facilitando a implementação de soluções como femtocélulas e repetidores internos para melhorar a cobertura.

A modelagem precisa de desvanecimento ajuda a prever e gerenciar a interferência entre células adjacentes, aumentando a capacidade da rede de suportar mais usuários simultâneos, permitindo uma alocação mais eficiente de recursos de espectro e melhorando sua utilização.

Em relação à Qualidade de Serviço (QoS), modelos aprimorados ajudam a manter a estabilidade da conexão em áreas com alta variabilidade de sinal, como ruas estreitas e áreas com muitos obstáculos; reduzir a frequência e a duração do desvanecimento melhora significativamente a experiência do usuário final em termos de velocidade, latência e estabilidade de dados.

Em áreas suburbanas, a modelagem avançada de desvanecimento pode otimizar a melhoria do alcance. Como a densidade da área é menor, a maior distância entre as células requer modelagem precisa para maximizar o alcance de cada célula sem comprometer a qualidade do sinal e para ajudar a mitigar a interferência ambiental causada pela vegetação e outras obstruções típicas de áreas suburbanas. Ainda em relação à economia de energia, a previsão precisa do desvanecimento permite ajustes dinâmicos na potência de transmissão, otimizando o consumo de estações base e dispositivos do usuário. Também pode aumentar a eficiência do uso do repetidor, garantindo cobertura adequada em regiões de baixa densidade.

Em relação ao processo de reconstrução do sinal, o modelo £ demonstrou ser vantajoso ao fornecer maior uniformidade em comparação ao modelo Nakagami-m. Isso é atribuído à sua capacidade de incorporar informações sobre a distribuição estatística do desvanecimento e características específicas do canal, resultando em uma reconstrução mais precisa e menos propensa a ruído e interferência. Além disso, a estrutura iterativa do modelo permite refinamentos sucessivos, melhorando a precisão da estimativa do canal em cenários complexos e impactando diretamente a qualidade do sinal reconstruído.

Em conjunto com o filtro de partículas, o modelo \mathcal{L} demonstrou eficiência na captura de uma ampla gama de comportamentos de ruído, incluindo variações rápidas e profundas, se adaptando rapidamente às variações dinâmicas e ajusta efetivamente as partículas e pesos no filtro. A supressão de ruído é mais eficiente, resultando em sinais reconstruídos com menores variações maior relação sinal-ruído (SNR).

No geral, o modelo \mathcal{L} provou ser uma ferramenta versátil para simular o desvanecimento em canais mmW e reconstrução de sinal. Essas características sugerem que o modelo pode ser uma ferramenta promissora para desenvolver redes de comunicação mais eficientes e precisas com suas características desafiadoras de propagação no espectro de ondas milimétricas.

Desenvolvimentos futuros relacionados ao modelo devem incluir validação com medições em campo, integração com técnicas avançadas de processamento de sinais, algoritmos de IA e aprendizado de máquina e o desenvolvimento de soluções que permitam a avaliação contínua e em tempo real de métricas de desempenho como LCR, AFD e BER.

8 REFERÊNCIAS

3GPP T.R. 38.901. Study on channel model for frequencies from 0.5 to 100 GHz. 2018.

3GPP TR 25.996. Spatial channel model for multiple input multiple output (MIMO) simulations. 2018.

3GPP TR 36.873. Study on 3D channel model for LTE. 2014.

5G INFRASTRUCTURE PUBLIC PRIVATE PARTNERSHIP - 5G PPP. 5G Infrastructure Public Private Partnership (5G PPP). Disponível em: https://5g-ppp.eu/.

ABDUL SALAM, A.; SHERIFF, R.; MEZHER, K.; NASIR, Q. Novel Approach for Modeling Wireless Fading Channels Using a Finite State Markov Chain. **ETRI Journal, Volume 39, Number**, 2017.

AL-SAMAN, A.; CHEFFANA, M.; ELIJAH, O.; et al. Survey of Millimeter-Wave Propagation Measurements and Models in Indoor Environments. **ELECTRONICS**, v. 10, n. 14, 2021.

ALEXANDROPOULOS, G.; SHLEZINGER, N.; FAQIRI, R. End-to-End Fading Channel Modeling for RIS-Empowered Smart Wireless Environments. IEEE Globecom Workshops (GC Wkshps). **Anais...** p.741–746, 2022. Rio de Janeiro.

ALISON BETH, L. K-distribution fading models for Bayesian estimation of an underwater acoustic channel, 2011. MIT.

ALKHATEEB, A.; BELTAGY, I.; ALEX, S. Machine learning for reliable mmwave systems: Blockage prediction and proactive handoff. **2018 IEEE Global Conference on Signal and Information Processing, GlobalSIP 2018 - Proceedings**, p. 1055–1059, 2019. Anahein, United State: Institute of Electrical and Electronics Engineers Inc.

ANDREWS, L. C.; PHILLIPS, R. L.; YOUNG, C. Y. Laser Beam Scintillation with Applications. 1st ed. SPIE Publications, 2001.

BATTACHARIA, C.; RIZVI, A.; GUPTA, N.; SHARMA, KI. Generation of Nakagami-m Statistics by Monte Carlo Method for Fading Communication Channels. Girinagar - India, 2010.

BORHANI, A. Modelling and Analysis of Non-Stationary Mobile Fading

Channels Using Brownian Random Trajectory Models, 2014. University of Agder.

CHANDRA, A.; CHATTOPADHYAY, S. Design of hardware efficient FIR filter: A review of the state-of-the-art approaches. **Engineering Science and Technology, an International Journal**, v. 19, p. 212–226, 2016.

CHAVAN, M. S. .; CHILE, R. H. .; SAWANT, S. R. Multipath Fading Channel Modeling and Performance Comparison of Wireless Channel Models. **International Journal of Electronics and Communication Engineering**, 2011.

CHEN, Z. Performance Analysis of Channel Estimation and Adaptive Equalization in Slow Fading Channel. 2007.

CHONG, H.; MA, S.; LEE, H.; CHO, M. Millimeter Wave Path Loss Modeling for 5G Communications Using Deep Learning with Dilated Convolution and Attention. **IEEE Access**, v. 9, p. 62867–62879, 2021.

COLLENGE, S.; ZAHARIA, G.; EL ZEIN, G. "Influence of the human activity on wide-band characteristics of the 60 GHz indoor radio channel. **IEEE Transactions on Wireless Communications**, v. 3, n. 6, p. 2396- 2406, 2004.

GARNETT, R. **Bayesian Optmization**. 1St ed. Washington University in St Louis: Cambridge University Press, 2022.

GHOSH, S.; SUDIR, C. Performance Analysis on the Basis of Comparative Study Between Multipath Rayleigh Fading and Awgn Channel in the Presence of Various Interference. **Iernational Journal of Mobile Network & Telamatics** (IJMNCT), v. 04, n. February, 2014.

GLAROT, X.; BORDES, A.; BENGIO, Y. Deep Sparse Rectifier Neural Networks. Proceedings of the Forteenth International Conference on Artificial intelligence and Statistics. **Anais...** p.315–23, 2011. Fort Lauderdale - FL - United States.

GUAN, K.; MORENO, J.; Al, B.; et al. 5G Channel Models for Railway Use Cases at mmWave Band and the Path Towards Terahertz. **IEEE Intelligent Transportation Systems Magazine**, p. 146–155, 2021.

HAMADE, I.; EL-HAJJAR, M.; KATLA, S.; HANZO, L. Millimeter-Wave Communications: Physical Channel Models, Design Considerations, Antenna Constructions, and Link-Budget. **IEEE Communications Surveys & Tutorials**, v. 20, 2018.

HARRINGTON, R. **Field Computation by Moment Methods**. Hoboken, N.J.: Willey-IEEE, 1993.

ICT-317669-METIS/D1.4. METIS Channel Models. 2015.

ICT-671650-MMMAGIC/W2.1. "White Paper: W2.1, 6 – 100 GHz channel modelling for 5G: measurement and modelling plans in mmMAGIC. , 2016. mmMAGIC.

INTERNATIONAL TELECOMMUNICATION UNION, I. Specific Attenuation Model for Rain for Use in Prediction Methods -ITU., 2005. Geneve - Switzerland.

ITU-R. ITU -R - Attenuation in Vegetation. Geneve - Switzerland, 2013.

JAKES, W. C. **Microwave Mobile Communications**. New York: John Willey e Sons, 1984.

JARINOVÁ, D. Fading Channel Prediction by Higher-Order Markov Model. **New Trends in Signal Processing (NTSP)**, p. 1–4, 2020.

JIANHUA, Z. Proposal on IMT-2020 channel model. **ITU - International Telecommunication Union**, 2020.

JIN, X.; ZANG, Y.; PAN, C. **A New Simulation Model of Rician Fading Channel**. Shenzhen, 2016.

JO, H.-S.; PARK, C.; LEE, E.; CHOI, H. K.; PARK, J. Path Loss Prediction Based on Machine Learning Techniques: Principal Component Analysis, Artificial Neural Network, and Gaussian Process. **Sensors**, v. 20(7) 1927, 2020.

KUMAR, P. S.; SUMITHRA, M. G.; SARUMATHI, M. Performance Comparison of Rayleigh and Rician Fading Channels In QAM Modulation Scheme Using Simulink Environment. **International Journal of Computational Engineering Research**, v. 03, n. 05, 2013.

KYOSTI, P.; MEINLA, J.; HENTILLA, L.; ZHAO, X. IST-4-027756 WINNER II channel models. 2008.

LAM, T. Fading model for wireless 5G mmW transmission. **2016 IEEE** International Symposium on Antennas and Propagation (APSURSI), p. 2067–2068, 2016.

LAVANIA, V.; SASIBHUSHANA, R.; BIDIKAR, B. Fast Fading Mobile Channel Modeling For Wireless Communication. In: ELSEVIER (Org.); International Conference on Computational Modeling and Security. **Anais...**, 2016.

LI, S.; LIU, Y.; CHEN, Z.; SUN, X.; LIN, L. Measurements and modelling of millimeter-wave channel at 28 GHz in the indoor complex environment for 5G radio systems. **2017 9th International Conference on Wireless Communications and Signal Processing (WCSP),** p. 01–06, 2017.

MALTSEV, A.; MASLLENNIKOV, R.; SEVASTYNOV, A.; A., L.; KHORYAIEV, A. Statistical channel model for 60 GHz WLAN systems in conference room environment. Proceedings of the Fourth European Conference on Antennas and Propagation. **Anais...** p.1–5, 2010.

MALTSEV, A.; PUDEYEV, A.; KARLS, I.; et al. Quasi-deterministic approach to mmWave channel modeling in a non-stationary environment. **IEEE Globecom Workshops (GC Wkshps)**, p. 966–971, 2014.

MARCUS, M.; PATTAN, B. Millimeter wave propagation: spectrum management implications. **Microwave Magazine**, **IEEE**, p. 54–62, 2005.

NOGA, K.; PALCZYNKA, B. Overview of Fading Channel Modeling. **INTL JOURNAL OF ELECTRONICS AND TELECOMMUNICATIONS**, v. VOL. 56, N, p. PP. 339–344, 2010.

NYU-NEW YORK UNIVERSITY. **MmWave channel modeling,**. New York, 2014.

OFFICE OF ENGINEERING AND; TECHNOLOGY. Millimeter Wave Propagation: Spectrum Management Implications. 1997.

OLSEN, R. L.; TJELTA, T.; MARTIN, L.; SEGAL, B. Worldwide techniques for predicting the multipath fading distribution on terrestrial L.O.S. links: Comparison with regional techniques. **IEEE Transactions on Antennas and Propagation**, v. 51, n. 1, p. 23–30, 2003.

PATZOLD, M.; WANG, CHENG-XIANG; HOGSTAD O., B. Two New Sum of Sinusoids Based Methods for the Efficient Generation of Multiple Uncorrelated Rayleigh Fading Waveforms. **IEEE**, 2009.

PUDEYEV, A.; MALTSEV, A.; LOMAYEV, A.; BOLOTIN, I. Channel modeling in the next generation mmWave Wi-Fi: IEEE 802.11ay standard. **22th European Wireless Conference**, p. 1–8, 2016.

RAHIM, H. M.; LEOW, C. Y.; RAHMAN, T. A.; ARSAD, A. Foliage attenuation measurement at millimeter wave frequencies in tropical vegetation. 2017 IEEE 13th Malaysia International Conference on Communications (MICC),. **Anais...** p.241–46, 2017. IEEE.

RANGAN, S.; RAPPAPORT, T. S.; ERKIP, E. Millimeter-wave cellular wireless networks: Potentials and challenges. **Proceedings of the IEEE**, v. 102, n. 3, p. 366–85, 2014.

RAO KUMAR, C. Asymptotic Analysis of Wireless Systems with Rayleigh

Fading, 2007. Caifornia Institute of Technology.

RASCHKOWSKI, L.; KYOSTI, P.; KUSUME, K.; JAMSA, T. **METIS Channel Models (D1.4)**. 2015.

Recommendation ITU-R M.2083-0 _ IMT Vision – Framework and overall objectives of the future development of IMT for 2020 and beyond M Series Mobile, radiodetermination, amateur and related satellite services. 2015.

ROSS, S. **Introduction to Probability Models**. 10th ed. Los Angeles: Elsevier, 2010.

S.RAPPAPORT, T. Coherence Bandwidth. , 2018. National Instruments/ Prentice Hall.

SAMIMI, M.; RAPPAPORT, T. S. 3-D Millimeter-Wave Statistical Channel Model for 5G Wireless System Design. **IEEE Transactions on Microwave Theory and Techniques**, v. 64, n. 7, p. 2207–2225, 2016.

SAUNDERS, P. Oxford Dictionay of Statistics. **The Mathematical Gazzete**, 2008.

SHAN, C.; ZHOU, W.; YANG, Y.; JIANG, Z. Multi-Fading Factor and Updated Monitoring Strategy Adaptive Kalman Filter-Based Variational Bayesian. **Sensors**, v. 198, n. 21(1), 2020.

SHARIAT, M.; GUTIERREZ-ESTEVEZ, D. M.; VIJAY, A.; et al. 5G radio access above 6 GHz. **Transactions on Emerging Telecommunications Technologies**, v. 27, n. 9, p. 1160–1167, 2016.

SHARMA, S.; MISHRA, R. A Simulation Model for Nakagami-m Fading Channel. International Journal of Advanced Computer Science and Applications, v. 6, 2015.

SKLAR, B. Rayleigh Fading Channels in Mobile Digital Communication Systems: Characterization. **IEEE Communications Magazine**, p. 90–100, 1997.

SMITH, E. K. Centimeter and millimeter wave attenuation and brightness temperature due to atmospheric oxygen and water vapor. **Radio Science**, v. 17, n. 6, p. 1455–1464, 1982.

TSAKALOZOS, N.; DRAKAKIS, K.; RICKARD, S. Chanel Models of the Doppler Efect. Dublin, 2010.

TURNER, R.; ERICKSSON, D.; ISABELLE, M. G.; MCCOURT, M. Bayesian Optimization is Superior to Random Search for Machine Learning Hyperparameter Tuning: Analysis of the Black-Box Optimization Challenge 2020. **Neural Information**

Processing, 2021.

VALENZUELA, R.; SALEH, A. A. M. statistical model for indoor multipath propagation,. **IEEE Journal on Selected Areas in Communications**, v. 5, n. 2, p. 128–137, 1987.

VAUGHAN, R.; BACH ANDERSEN, J. Channels, Propagation, and Antennas for Mobille Communication. 2002.

WEI, H.-Y. Wireless Channel and Radio Propagation., 2014. Taiwan.

XIAO, M.; MUNTAZ, S.; HUANG, Y.; et al. Millimeter wave communications for future mobile networks. **in IEEE Journal on Selected Areas in Communications**, v. 35, n. 9, p. 1909–35, 2017.

YEE, K. Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media. **IEEE Transactions on Antennas and Propagation**, v. 14, n. 3, p. 302–307, 1966.

YOUSSEF, Y. Bayes Theorem and Real-life Applications. **Cairo University - Computing Department**, 2022.

ZHANG, J.; SHEN, X.; ZHANG, K. Wireless Fading Channel Model for 5G and Future. **Encyclopedia of Wireless Networks**. p.1483–1488, 2020. Springer.

ZHANG, Y.; WEN, J.; YANG, G.; HE, Z.; LUO, X. Air-to-air path loss prediction based on machine learning methods in urban environments. **Wireless Communication and Mobile Computing**, v. 2018, n. Special Issue, 2018.

ZHAO, H.; MAYZUS, R.; SHU, S.; SAMIMI, M.; RAPPAPORT, T. S. 28 GHz millimeter wave cellular communication measurements for reflection and penetration loss in and around buildings in New York City. In: IEEE (Org.); IEEE International Conf. on Communications (ICC). **Anais...**, 2013.