

Aplicação dos Modelos Ocultos de Markov na Caracterização Banda Larga do Canal Rádio *Indoor*

Rafael S. Azevedo, Leni J. Matos e Edson Cataldo

Programa de Pós-graduação Stricto Sensu em Engenharia Elétrica e de Telecomunicações - PPGEET

Universidade Federal Fluminense

Niterói, Brasil

rafaelazevedo@id.uff.br, ecataldo@id.uff.br, lenijm@id.uff.br

Resumo— Esse trabalho objetiva modelar o canal rádio móvel banda larga em ambiente interno empregando modelos ocultos de Markov aos principais parâmetros de dispersão temporal do canal. Ao provar a viabilidade de tal modelagem, o uso da técnica empregada mostra-se como uma poderosa opção para a caracterização estatística do canal rádio.

Palavras-Chave— Canal rádio indoor, faixa larga, modelos ocultos de Markov, topologia Bakis, varredura em frequência.

Abstract— This paper aims to model the broadband mobile radio channel at indoor environment applying hidden Markov models to the main temporal dispersion parameters of the channel. When proving the feasibility of such modeling, the employed technique is shown to be a powerful option for the statistical characterization of the radio channel.

Keywords— Indoor radio channel, broadband, hidden Markov models, Bakis topology, swept frequency (chirp).

I. INTRODUÇÃO

Em vista da evolução contínua dos sistemas de comunicações móveis, parâmetros como a taxa de transmissão de dados e a latência são aprimorados a cada geração. Esses sistemas de alto desempenho evoluem para suportarem uma vasta variedade de dispositivos e serviços.

Os atuais sistemas de telefonia móvel celular, cada vez mais, usam combinações de frequências e novas tecnologias. A atual tecnologia IMT-2020 (comumente denominada 5G), para lidar com diferentes cenários de implementação e ofertar uma vasta gama de serviços, pode utilizar faixas de frequências mais baixas (denominadas FR1 ou Sub 6 GHz, com larguras de banda de até 100 MHz) ou empregar frequências mais altas (denominadas FR2 ou *mmWave* – ondas milimétricas, com larguras de banda de até 400 MHz) [1]. Soma-se a isso o fato dessa nova tecnologia ainda usar agregações espectrais e múltiplas antenas, combinando dinamicamente diferentes faixas de frequências para aumentar a banda de transmissão e ganhar eficiência, desempenho e suprir as necessidades de diferentes segmentos de mercado [2-3].

Ao passo do atual estágio de desenvolvimento dos sistemas de comunicações móveis, o aperfeiçoamento de tais sistemas engloba não apenas melhorias em dispositivos móveis como também uma análise mais apurada e o adequado dimensionamento do canal rádio móvel (CRM). Para tal, propostas de modelagem faixa larga do CRM tornam-se extremamente importantes e visam somar-se aos já existentes e consagrados modelos físicos de caracterização estatística do CRM, tais como: modelo Saleh-Valenzuela [4-5], que caracteriza o comportamento dispersivo do canal rádio *indoor* no domínio do tempo através da geração sucessiva de respostas instantâneas; modelo auto-regressivo [6-7], que calcula os parâmetros do modelo a partir de medições realizadas de resposta do canal na frequência e

emprega o princípio da máxima entropia; e modelo de geração e desaparecimento de raios [8-9], que descreve estatisticamente os parâmetros (amplitude, fase e retardo) associados a cada multipercurso gerado pelo canal no domínio do tempo.

Dessa forma, o emprego do modelo oculto de Markov (HMM) na modelagem estatística dos parâmetros do canal traz uma nova forma de modelagem, que tem satisfatória aplicação em sinais que variam com o tempo, pois endossa, em sua natureza probabilística e adaptativa, a maior vantagem para caracterizar sinais corrompidos por ruído, tais como a fala, a escrita e o próprio sinal rádio. A ideia para o emprego de tal modelagem foi inspirada no uso do método HMM para identificação de locutor, no qual se observam os estados como fonemas de uma palavra.

Nesse contexto, este trabalho objetiva a aplicação do HMM na modelagem do CRM faixa larga em ambiente *indoor*, partindo de parâmetros de dispersão temporal do CRM como o retardo médio e o espalhamento de retardo. É uma continuidade do artigo de Ribeiro [10], no qual o HMM é empregado para caracterizar estatisticamente o canal rádio *indoor*, conduzindo a novos resultados.

Esse artigo está organizado da seguinte forma: a Seção II descreve sucintamente a função do canal e aplicação de HMM; a Seção III descreve o ambiente de medições; a Seção IV expõe a metodologia proposta para a aplicação do HMM; a Seção V trata das simulações e provê os resultados e a Seção VI discorre sobre as conclusões e direcionamentos para trabalhos futuros.

II. CARACTERIZAÇÃO DO CANAL RÁDIO E MODELOS OCULTOS DE MARKOV

A. Caracterização do Canal Rádio Móvel

A representação de um fenômeno complexo, mesmo que simplista quando comparado à realidade, pode ajudar na entrega de um resultado desejado, pode também proporcionar uma melhor compreensão da sua origem geradora, ou ainda pode proporcionar uma descrição teórica que exponha o comportamento adequado do próprio fenômeno [11].

Fenômenos como o CRM associam sinais de excitação e resposta por meio de processos ditos estocásticos, representando sequências evolutivas de eventos com o tempo. Embora se observe essa resposta aleatória do CRM com variação temporal, pode-se incorporar uma natureza de tempo invariante ao acatar o processo como um encadeamento de curtos espaços de tempo, transformando-se em um somatório de pequenos intervalos com características estatísticas comuns que apresentam estabilidade, evolução e estacionariedade temporal.

Ao considerar a evolução de cada processo como a concatenação de curtos espaços temporais [12], onde se pondera que as variáveis assumem valores discretos e as autocorrelações são invariantes durante pequenas transições temporais, admite-se trabalhar com modelos quase estacionários no sentido amplo com espalhamentos descorrelacionados QWSSUS (*Quasi-Wide-Sense Stationary Uncorrelated Scattering*).

B. Aplicabilidade dos Modelos Ocultos de Markov

O método estatístico nomeado modelos ocultos de Markov possui um importante papel na modelagem de sistemas dinâmicos [13], visto que assegura em sua natureza aleatória, adaptativa e iterativa, uma excelente oportunidade para caracterização de sistemas complexos, com aspectos temporais e até mesmo, corrompidos por outras fontes e ruídos [14].

Diante disso, o HMM tem sido amplamente estudado e adotado em diferentes contextos [10] [11] [15] [20]. À vista de sua robustez, com algoritmos iterativos que acabam por ajustar automaticamente os parâmetros do modelo, o HMM serviu de base para a modelagem e análise do CRM, onde cada estado agrupou seus respectivos parâmetros de dispersão temporal do CRM e as transições entre os estados geraram seus respectivos observáveis.

III. CENÁRIO DE MEDIÇÕES

A. Cenário de Medições

Para caracterização do CRM em faixa larga e em ambiente interno, adotou-se uma técnica de sondagem no domínio da frequência denominada varredura em frequência, onde um sinal senoidal de 10 dBm foi gerado e transmitido, sucessivamente, em frequências discretas e igualmente espaçadas ao longo de uma banda de frequência de 750 MHz (de 960 MHz até 1710 MHz) [17].

Usou-se um transceptor (analisador vetorial de rede) devidamente calibrado que, pela porta de transmissão, varreu toda a banda de frequência com as respectivas portadoras senoidais de 10 dBm e, ao mesmo tempo, monitorou a porta de recepção. Os principais parâmetros do sistema de medições estão na Tabela I.

TABELA I. PARÂMETROS DO SISTEMA DE SONDAÇÃO [17].

Parâmetro	Valor	Unidade
Faixa de Frequência	960 a 1710	MHz
Largura de Banda	750	MHz
Potência de Transmissão	+10	dBm
Ganho do LNA	25	dB
Ganho das Antenas	2,14	dB
Espaçamento em Frequência entre amostras - Δf	0,46875	MHz
Número de Amostras Varridas	1601	-
Tempo de varredura	696	ms
Resolução Temporal - $\Delta \tau$	1,333	ns
Retardo Máximo - τ_{MAX}	2133	ns

IV. METODOLOGIA PROPOSTA

A. Aquisição e processamento dos dados no canal testado

Os sinais recebidos, medidas consecutivas de amplitudes e fases da resposta em frequência do canal, correspondem às respostas do canal frente à varredura das portadoras senoidais e, dessa forma, dizem respeito à função de transferência do canal $T(f, t)$ definida como a resposta em frequência do CRM para cada curto intervalo temporal [16].

A recepção foi montada para aquistar $T(f, t)$ em sete diferentes localidades de medição, variadas de RX1 a RX7, mostradas na Fig.1. Para cada localidade foi montada uma malha quadrangular 6 por 6, com 36 posições de recepção espaçadas igualmente de 15 cm [17]. Como $0,38 \lambda$ representa o primeiro zero de correlação entre medições [16], a distância de 15 cm foi suficiente para garantir que as medições das 36 posições de cada localidade não estivessem correlacionadas. Sendo a banda de frequência larga, os valores de λ variaram entre 17,54 cm (frequência superior de 1710 MHz) e 31,25 cm (frequência inferior de 960 MHz) e $0,38 \lambda$ corresponde, respectivamente, a 6,7 cm e 11,9 cm. De onde se conclui que o espaçamento de 15 cm entre os pontos da malha foi suficiente para assegurar a descorrelação entre os sinais medidos nos 36 pontos. As malhas permitiram o levantamento de estatísticas de pequena escala do CRM em cada uma das 36 posições de cada uma das sete localidades de medição.

Ao longo de cada varredura, de 696 ms para o equipamento empregado, realizada em cada posição de recepção fixa, praticamente não havia variação temporal do sinal recebido e a função $T(f, t)$ obtida estava composta apenas de amostras discretas de amplitudes e fases. Sendo o canal considerado como um filtro linear, os registros de entrada e saída caracterizaram diretamente $T(f, t)$. Usou-se a função janela *Blackman-Harris* de 3 termos para minimizar o vazamento espectral [17], provocado pela discretização, e aplicou-se a Transformada Discreta Inversa de Fourier (IDFT) para obtenção dos perfis de potência de retardo $P_h(\tau)$ [16]. Nesses perfis, foi aplicada a técnica CFAR (*Constant False Alarm Rate*) para limpeza de ruído [10], evidenciando apenas percursos válidos, através de suas amplitudes e retardos. Após o pré-processamento desses dados, obtiveram-se os parâmetros para caracterização do CRM: retardo médio, τ_m , e espalhamento de retardo, σ_T [16]. Dessa forma, para cada posição da malha quadrangular de cada localidade de medição (RX1 a RX7), geraram-se matrizes com valores de τ_m e σ_T . Essas formatações das amostras em matrizes bidimensionais do tipo 36 x 2 foram denominadas de matrizes de características por localidade.




Fig. 1. Planta do ambiente de medição: hall do prédio de Engenharia UFF [17].

B. Topologia Bakis

A reflexão sobre a escolha de uma topologia propícia para o uso do HMM na modelagem de sistemas reais é de grande valia. Isso fica claro quando se pensa nas iterações necessárias ao modelo e na quantidade de processamento para treinamento do modelo. Quanto mais livre a topologia, maior será o número de possíveis caminhos entre estados a serem percorridos. Visto que a execução prática impõe limites ao tamanho do modelo [11-13], deve-se considerar, sempre que possível, a devida restrição no número de caminhos a serem percorridos, ou seja, busca-se sempre um equilíbrio entre flexibilidade e eficiência para a modelagem adotada. Em vista disso, adotou-se a topologia Bakis [11-15], uma simplificação da topologia esquerda-direita (*left-to-right*), só permitindo transições para adiante, conduzindo a uma matriz de transições triangular. Ela traz maior eficiência para as iterações e treinamentos necessários, mantendo ainda certa flexibilidade, e apresenta uma estrutura temporal. Por assim dizer, essa topologia permite a transição para o estado subsequente, a permanência no próprio estado, ou o salto de apenas um estado subsequente, como visto na Fig.2.




Fig. 2. Topologia Bakis [11][15].

C. Caracterização do CRM com uso do HMM

Após a aquisição dos parâmetros de retardo médio τ_m e espalhamento de retardo σ_T para cada localidade e respectivo armazenamento nas matrizes de características por localidade, era necessário adequar os dados de sondagem do CRM ao funcionamento do *toolkit* do HMM para Matlab [19]. Para tal adequação, as matrizes de características das localidades RX1 a RX7 correspondem aos estados. As transições entre duas localidades, conforme a topologia Bakis, permitiram agrupar os parâmetros de dispersão τ_m e σ_T do CRM em matrizes tridimensionais do tipo $2 \times 2 \times 36$, reunindo aleatoriamente dois a dois os 36 parâmetros τ_m e σ_T de cada localidade. Essas matrizes tridimensionais foram denominadas de matrizes de características de transição e, no contexto do HMM, correspondem aos observáveis.

Quando as matrizes de características de transição foram agrupadas, indicando a passagem de um estado para outro, indo de RX1 até RX7, segundo a topologia Bakis, formou-se a matriz base de características do CRM com quatro dimensões. Essa matriz base foi dividida ao meio entre matriz base de treinamento e matriz base de teste. Dessa forma, 50% dos dados foram utilizados para inicialização e treinamento com o algoritmo Baum-Welch [10], enquanto outros 50% foram tratados na seguinte sequência: obtiveram-se as medidas de log-verossimilhança para todas as amostras da matriz base de teste, retiraram-se os valores discrepantes em relação aos demais (*outliers*), separaram-se igualmente os dados em grupo de referência (25% para o cálculo dos

limiares criados) e grupo de teste (25% para testar os limiares). Para treinar o HMM na caracterização do CRM, consideraram-se as etapas de inicialização e treinamento. Para inicialização, efetuaram-se varreduras para descobertas de valores ótimos. Ainda no processo de inicialização, supondo que cada estado costuma gerar grupos de observáveis tipicamente próximos, executou-se análise de agrupamento (*clustering*) com o algoritmo iterativo *k-means* para reunir vetores de observáveis semelhantes entre si e para associar esses vetores às misturas gaussianas dos estados.

Ainda na etapa de treinamento, usou-se o algoritmo Baum-Welch para treinamento e maximização dos parâmetros do modelo. Com base nos valores iniciais, fez-se o cálculo dos caminhos mais prováveis (*expectation*) e o recálculo das probabilidades com base nos novos caminhos calculados anteriormente (*maximization*). Esse processo gerou novos valores iniciais que foram utilizados no lugar dos antigos. Dessa forma, criou-se iterações até que os cálculos alcançassem um critério de parada, que poderia ser pouca melhora na verossimilhança em comparação com os parâmetros anteriores, ou número limite de iterações, ou ainda uma combinação entre os dois critérios anteriores.

Para a matriz base de teste, com relação ao grupo de referência, os dados foram usados para a definição de limiares. Esses correspondem aos valores de log-verossimilhanças usados como referências, ou seja, para cada matriz de características de transição de um estado para outro, serão log-verossimilhanças válidas os valores do grupo de teste que estão acima do limiar analisado. Foram definidos quatro diferentes limiares, descritos na Tabela II, com os quais os grupos de teste foram comparados [10-18].

TABELA II. ESPECIFICAÇÃO DOS LIMIARES ESCOLHIDOS [10].

Limiares	Especificações
1. Média das médias	Média aritmética simples entre a média das log-verossimilhanças da localidade em questão e demais localidades.
2. Média Cruzada	Média das log-verossimilhanças da localidade em questão é multiplicada pelo desvio-padrão das log-verossimilhanças das demais localidades. Média das log-verossimilhanças das demais localidades é multiplicada pelo desvio-padrão das log-verossimilhanças da localidade em questão. Calcula-se a média aritmética simples dos dois valores obtidos.
3. Percentil P20 das log-verossimilhanças	Limiar é posicionado de modo a ser maior que 20% das log-verossimilhanças da localidade em questão e demais localidades.
4. Percentil P20 das f.d.p.	Limiar separa 20% da área sob a f.d.p. das log-verossimilhanças à sua esquerda e os demais 80% à sua direita.

Para a matriz base de teste, com relação ao grupo de teste, os valores de log-verossimilhanças foram usados para estimação de funções de densidade de probabilidade (comando *ksdensity*). Para cada transição entre estados, obteve-se uma função densidade de probabilidade.

Em posse dos valores dos limiares e das log-verossimilhanças, os resultados foram obtidos através de:

- Análise gráfica de funções de densidade de probabilidade versus limiares calculados. Cada gráfico indica os 4 limiares calculados e as funções de densidade de probabilidade, com base no HMM treinado para cada transição de estados.

- Análise dos modelos HMM treinados. Usou-se uma matriz de confusão para classificar o posicionamento das log-verossimilhanças em relação aos limiares calculados para cada transição de estados.

V. SIMULAÇÕES E RESULTADOS

A. Simulação I: transições aleatórias entre os estados

Para a simulação I, a topologia Bakis gerou transições aleatórias de estados, ou seja, o programa em Matlab gerou aleatoriamente as transições entre as localidades RX1 e RX7. Como exemplo, foram geradas 7 transições:

- RX1 para RX1 (transição 1 representado por 1-1).
- RX1 para RX3 (transição 2 representado por 1-3).
- RX3 para RX4 (transição 3 representado por 3-4).
- RX4 para RX5 (transição 4 representado por 4-5).
- RX5 para RX5 (transição 5 representado por 5-5).
- RX5 para RX7 (transição 6 representado por 5-7).
- RX7 para RX7 (transição 7 representado por 7-7).

Cada transição entre localidades definiu uma matriz de características de transição que permitiu agrupar os parâmetros de dispersão τ_m e σ_T das respectivas localidades em matrizes tridimensionais do tipo 2x2x36. Metade das amostras de cada matriz de características de transição foi usada para treinamento do HMM e a outra metade foi destinada para teste e validação. Para inicialização, atribuiu-se o valor 2 ao número de estados, pois a análise foi feita para cada transição. Para as misturas gaussianas e o número de iterações, efetuaram-se varreduras para descobrir os valores ótimos e esses foram, respectivamente, 2 e 20.

Com a metade reservada para teste e validação, foram realizados os seguintes passos:

- Valores de log-verossimilhanças foram calculados com base em todo o conjunto de dados.
- 2 valores de *outliers* foram retirados para cada matriz de características de transição.
- 50% das amostras de teste e validação foram usadas para calcular limiares.
- 50% das amostras de teste e validação foram usadas para testar os limiares calculados.

O exame dos resultados, com base na análise gráfica, pode ser visualizado na Fig. 3. A linha vermelha corresponde aos valores de log-verossimilhança da transição 3-4. As demais curvas de densidade de probabilidade correspondem aos valores de log-verossimilhanças das outras 6 transições. Percebe-se que o limiar 3, que corresponde ao percentil P20 das log-verossimilhanças, é o que apresenta melhor ajuste na identificação das log-verossimilhanças da transição 3-4. Isso porque os valores de log-verossimilhança da transição 3-4 encontram-se à direita do limiar 3 e os demais valores encontram-se à esquerda do mesmo.

Comportamento análogo foi observado para os gráficos das demais 6 transições. De onde se inferiu que o limiar 3 (percentil P20 das log-verossimilhanças) é a melhor escolha entre as quatro opções consideradas.

O mesmo resultado foi apresentado quando se analisou a matriz de confusão gerada. Levando-se em conta apenas o limiar 3, limiar com melhor resultado, é possível montar uma matriz de confusão para cada transição de estados. Essa matriz de confusão pode ser vista na Tabela III.




Fig. 3. Gráfico de estimativa de função densidade de probabilidade para a transição 3-4.

No total, foram testados 56 valores de log-verossimilhança. Oito deles são valores de teste de log-verossimilhança da matriz de características de transição que se está analisando, e 48 são valores das demais 6 transições de estados. Observa-se, na Tabela III, que as porcentagens das colunas verdadeiro positivo e falso negativo dizem respeito apenas aos valores da transição de estados corrente. Pegando como exemplo a própria transição de estados 3-4, o HMM acertou todos os 8 valores testados (não apresentou falsos negativos).

TABELA III. MATRIZ DE CONFUSÃO PARA CADA TRANSIÇÃO DE ESTADOS

Transição de Estados	Verdadeiro Positivo	Falso Negativo	Verdadeiro Negativo	Falso Positivo
1-1	12,5% (7/8)	1,8% (1/8)	69,6% (39/48)	16,1% (9/48)
1-3	10,7% (6/8)	3,6% (2/8)	82,1% (46/48)	3,6% (2/48)
3-4	14,3% (8/8)	0% (0/8)	83,9% (47/48)	1,8% (1/48)
4-5	10,7% (6/8)	3,6% (2/8)	46,4% (26/48)	39,3% (22/48)
5-5	8,9% (5/8)	5,4% (3/8)	1,8% (1/48)	83,9% (47/48)
5-7	10,7% (6/8)	3,6% (2/8)	35,7% (20/48)	50% (28/48)
7-7	12,5% (7/8)	1,8% (1/8)	78,6% (44/48)	7,1% (4/48)

O mesmo raciocínio é visto para as colunas verdadeiro negativo e falso positivo. Essas colunas correspondem aos valores das outras 6 transições de estados e, analisando novamente a transição de estados 3-4, é possível observar que o HMM rejeitou acertadamente 47 de 48 valores de log-verossimilhança.

B. Simulação II: transições determinadas entre os estados

Ao passo que a simulação I analisou cada transição individualmente, a simulação II propôs-se a analisar o conjunto de transições como um todo. Para isso, a topologia Bakis gerou transições pré-definidas de estados. Ou seja, definiu-se, de antemão, como ocorreriam as transições entre as localidades RX1 e RX7. Foram estabelecidas 9 transições:

- RX1 para RX2 (transição 1 representado por 1-2).
- RX2 para RX2 (transição 2 representado por 2-2).
- RX2 para RX3 (transição 3 representado por 2-3).
- RX3 para RX4 (transição 4 representado por 3-4).
- RX4 para RX4 (transição 5 representado por 4-4).
- RX4 para RX5 (transição 6 representado por 4-5).
- RX5 para RX6 (transição 7 representado por 5-6).
- RX6 para RX6 (transição 8 representado por 6-6).
- RX6 para RX7 (transição 9 representado por 6-7).

Uma matriz de características de transição do tipo 2x2x36 foi gerada para cada uma das 9 transições acima mencionadas, agrupando os parâmetros τ_m e σ_T das

respectivas localidades. Essas matrizes foram reunidas, formando uma matriz base de características do tipo 2x2x36x9. Metade das amostras da matriz base de características foi reservada para treinamento do HMM e a outra metade foi destinada para teste e validação. Cabe ressaltar que essa divisão foi feita para cada transição, de modo que tanto a base de treinamento quanto a de teste e validação agrupassem dados de todas as transições. Para inicialização, atribuiu-se valor 10 ao número de estados. Para as misturas gaussianas e número de iterações, fez-se novas varreduras com valores ótimos 2 e 20, respectivamente.

Isso posto, para a metade atribuída ao conjunto de teste e validação, seguiu-se com o cálculo dos valores de log-verossimilhança, retirada de *outliers*, divisão das amostras para determinação e teste dos limiares.

O exame dos resultados, com base na análise gráfica, pode ser visto na Fig. 4. A linha vermelha corresponde aos valores de log-verossimilhança do conjunto total de transições. Percebe-se que o limiar 3 ainda é o que apresenta melhor ajuste na identificação das log-verossimilhanças válidas, uma vez que esses valores de log-verossimilhança, em sua maioria, encontram-se à direita do limiar 3.




Fig. 4. Gráfico de estimativa de função densidade de probabilidade para o conjunto de todas as transições.

Nota-se que não existiram as demais curvas de densidade de probabilidade, visto que a análise aqui é feita com toda a matriz base de características (conjunto total com 9 transições). Além disso, para a matriz de confusão, não existiram dados para as colunas verdadeiro negativo e falso positivo, visto que não houve comparações entre diferentes transições.

Como feito na simulação I, levando-se em conta apenas o limiar 3, é possível montar a matriz de confusão vista na Tabela IV. Ao todo, foram testados 79 valores de log-verossimilhança e o HMM acertou 72. Assim sendo, ele rejeitou erroneamente apenas 7 valores testados.

TABELA IV. MATRIZ DE CONFUSÃO PARA O CONJUNTO DE TRANSIÇÕES

Transição de estados	Verdadeiro Positivo	Falso Negativo	Verdadeiro Negativo	Falso Positivo
1-2/ 2-2/ 2-3/ 3-4/ 4-4/ 4-5/ 5-6/ 6-6/ 6-7	91,1% (72/79)	8,9% (7/79)	0% (0/79)	0% (0/79)

VI. CONCLUSÕES

A partir da descrição dos cenários e resultados expostos, é possível afirmar que o método HMM ratifica as estatísticas

dos principais parâmetros de dispersão temporal do CRM (τ_m e σ_T) e ainda legítima o uso do HMM para análise do CRM com diferentes quantidades de transições de estados.

Para trabalhos futuros, avistam-se possibilidades de estudos comparativos com diferentes quantidades de transições de estados, bem como com diferentes cenários de medição do CRM como ambientes densamente urbanos, urbanos, suburbanos, residenciais, rurais e veiculares.

REFERÊNCIAS

- [1] 3GPP TR 21.915 V15.0.0 (2019-09). Release 15 Description.
- [2] 3GPP TR 21.916 V16.1.0 (2022-01). Release 16 Description.
- [3] 3GPP TR 21.917 V0.2.0 (2022-01). Release 17 Description.
- [4] A. A. M. Saleh e R. A. Valenzuela, *A statistical model for indoor multipath propagation*, IEEE J. Select. Areas Commun., v. 5, pp. 128–137, Fevereiro 1987.
- [5] F. V. S. Coelho e E. Cataldo e L. J. Matos. *Simulation of Indoor-Outdoor and Outdoor-Indoor Radio Channel in 960-1700 MHz Band*. IEEE Latin America Transactions, v. 15, p. 1400-1406, 2017.
- [6] S. Horward e K. Pahlavan, *Autoregressive Modeling of Wide-Band Indoor Radio Propagation*, IEEE Transaction on Commun., v. 40, pp. 1540-1552, Setembro 1992.
- [7] F. A. L. Silva, L. J. Matos e E. Cataldo, “Modelo auto-regressivo aplicado a um canal rádio de banda ultralarga”. XVI Simpósio Brasileiro de Telecomunicações – SBrT’08, 02-05 de Setembro de 2008, Rio de Janeiro, RJ.
- [8] H. Iwai, Y. Karasawa, *Wideband Propagation Model for the Analysis of the Effect of the Multipath Fading on the Near-Far Problem in CDMA Mobile Radio Systems*, IEICE, Trans. Comm., Vol E 76-B, pp-103-112, fev 1993.
- [9] R. V. S. Almeida e L. J. Matos, “Emprego da técnica de geração e desaparecimento de raios na simulação de canal UWB em ambiente indoor”. Em XXVII Simpósio Brasileiro de Telecomunicações – SBrT 2009, de 29 de Setembro a 02 de Outubro de 2009, Blumenau, SC.
- [10] L. G. Ribeiro, L. J. Matos e E. Cataldo, “Aplicação de modelos ocultos de Markov na modelagem do canal rádio móvel”. Em: MOMAG2020, 2020, Niterói. 19o. Simpósio Brasileiro de Micro-Ondas e Optoeletrônica/14o. Congresso Brasileiro de Eletromagnetismo. São Caetano do Sul: SBMO, 2020. v. 1. p. 296-300, 2021.
- [11] L. R. Rabiner, *A Tutorial on HMM and Select App in Speech Recognition*, Proceedings of the IEEE, Vol. 77, n. 2, Feb. 1989.
- [12] L. R. Rabiner, B. H. Juang, *An Introduction to Hidden Markov Models*. IEEE ASSP Magazine, 3, 4-16.
- [13] J. P. Coelho, T. M. Pinho, J. Boaventura-Cunha. *Hidden Markov Models: Theory and Implementation using Matlab®* (1st ed.). CRC Press, 2019.
- [14] A. B. Poritz, *Hidden Markov Model: A Guided Tour*, Proc. Of the IEEE Int. Conf. on in Acoustics, Speech, and Signal Processing, pp. 7- 13, 1988.
- [15] F. Jelinek, *Continuous Speech Recognition by Statistical Methods*, Proc. IEEE, Vol. 64, pp. 532-556, April 1976.
- [16] J. D. Parsons, *Wideband Channel Characterization - The Mobile Radio Propagation Channel*, Inglaterra: John Wiley & Sons Ltd, 2000, 418 p. cap. 6, pp. 164-189.
- [17] C. F. Souza. “Análise da dispersão temporal de canais de banda ultralarga (UWB) através de medidas realizadas em ambientes internos e externos”. Dissertação (mestrado) – Universidade Federal Fluminense, Niterói, Rio de Janeiro, 2006.
- [18] S. H. Chen, Y. R. Luo, *Speaker verification using MFCC and support vector machine, in proceedings of the international multicference of engineers and computer scientist*. IMECS-2009.
- [19] K. Murphy, *Hidden Markov Model (HMM) Toolbox for Matlab*, University of British Columbia, 2015.
- [20] F. J. S. Campos, *Modelos Ocultos de Markov: Del Reconocimiento de Voz a la Música*, Universidad de Granada, Sept. 2007.