



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Aplicação de Aprendizado de Máquina para Previsão de Ocupação de Espectro de Longa Duração

Rodrigo Feitosa Bezerra

Dissertação apresentada como requisito parcial para
conclusão do Mestrado em Informática

Orientador
Prof. Dr. Jacir Luiz Bordim

Brasília
2021



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Aplicação de Aprendizado de Máquina para Previsão de Ocupação de Espectro de Longa Duração

Rodrigo Feitosa Bezerra

Dissertação apresentada como requisito parcial para
conclusão do Mestrado em Informática

Prof. Dr. Jacir Luiz Bordim (Orientador)
CIC/UnB

Prof. Dr. Divanilson Rodrigo de Sousa Campelo Prof. Dr. Marcelo Antonio Marotta
CIn/UFPE CIC/UnB

Prof. Dr. Marcos Fagundes Caetano (Suplente)
CIC/UnB

Prof. Dr. Ricardo Pezzuol Jacobi
Coordenador do Programa de Pós-graduação em Informática

Brasília, 03 de Novembro de 2021

Dedicatória

Dedico este trabalho primeiramente aos meus pais, que sempre foram apoiadores na educação de todos os seus filhos. Dedico também este trabalho à minha esposa, que sempre me incentivou a buscar crescimento profissional e pessoal.

Agradecimentos

Agradeço a Deus por me proporcionar a oportunidade de realizar o sonho e concluir o mestrado.

Quero agradecer aos meus pais, seu Luis e dona Geralda, por incentivarem a dedicação aos estudos e por proporcionar os meios adequados para que eu pudesse me dedicar.

Agradeço à minha esposa, minha família, que sempre foi meu porto seguro e inspiração para esta jornada. Ainda nos seus primeiros passos ela me mostrou o caminho da pesquisa, pela qual mantenho um amor particular.

Agradeço ao Prof. Dr Jacir Luiz Bordim, meu orientador, que incontáveis horas dedicou a este trabalho com excepcional dedicação e interesse. Pelos inúmeros ensinamentos a mim dispensados nestes anos de trabalho juntos.

Agradeço aos Professores Dr. Marcus Vinicius Lamar e Dr. Marcos Fagundes Caetano pela cooperação técnica durante o desenvolvimento deste trabalho. Agradeço a paciência durante as apresentações das ideias confusas e embrionárias apresentadas durante nossas reuniões que foram lapidadas para formar a contribuição que este trabalho entregou.

Agradeço ao meu chefe imediato M.Sc. Henrique Primo Vieira que acreditou no meu potencial e não mediu esforços para viabilizar minha participação no programa de mestrado.

Resumo

A política de alocação estática do espectro aliada com a crescente demanda por altas taxas de dados têm estimulado a busca por estratégias alternativas de alocação. Neste contexto, Acesso Oportunista ao Espectro (do inglês, *Opportunistic Spectrum Access* - OSA) tem sido considerado uma alternativa para permitir que porções licenciadas do espectro sejam compartilhadas com usuários não licenciados. OSA requer que usuários não licenciados identifiquem porções do espectro para acesso oportunista de modo a minimizar possíveis interferências com os usuários licenciados. Este trabalho investiga o desempenho de um preditor padrão baseado no Modelo de Markov Escondido (do inglês *Hidden Markov Model* - HMM) projetado para realizar previsões de longa duração em dois cenários com comportamento do Usuário Primário (do inglês, *Primary User* - PU) distintos, sendo o preditor elaborado agnóstico ao cenário ao qual será aplicado. O primeiro cenário foi gerado de forma sintética a partir de uma distribuição de Poisson. O segundo cenário foi obtido a partir de uma base de dados pública de coleta de uma rede sem fio. Com base nos resultados obtidos com este preditor no cenário sintético, desenvolvemos dois aprimoramentos aplicados ao preditor com HMM que se mostraram efetivos na redução da quantidade de colisões e no aumento do aproveitamento das oportunidades. Estes aprimoramentos permitiram a redução da taxa de colisão média para 45,1% e o aumento do aproveitamento das oportunidades em 4,9% em relação ao preditor especificado na literatura. Na base pública utilizada um novo preditor foi introduzido. Um preditor baseado em Floresta Aleatória (do inglês, *Random Forest* - RF) foi implementado e avaliado nos mesmos cenários que o preditor com HMM. Os resultados mostraram que nos cenários menos complexos da base, onde há pouca variabilidade no comportamento do PU, os dois preditores tiveram desempenhos semelhantes. Nos cenários de maior variabilidade o preditor com HMM obteve, em média, 10% menos colisão que o preditor com RF. No entanto, esse último foi capaz de aproveitar, em média, 6,9% mais oportunidades do que o primeiro.

Palavras-chave: Modelo de Markov Escondido, Previsão de Oportunidades, Rádio Cognitivo, Acesso oportunista ao Espectro, Inferência de Espectro.

Abstract

Static spectrum allocation policies allied with the increasing demand for higher data rates stimulated the pursuit of alternative spectrum allocation strategies. In this context, Opportunistic Spectrum Access (OSA) has been considered an alternative to allow licensed portions of the spectrum to be shared with unlicensed users. OSA requires unlicensed users to identify unused portions of the spectrum for opportunistic access that minimizes possible interference with the licensed users. This work investigates the performance of a standard Hidden Markov Model (HMM) predictor that was designed to work with long term prediction in two distinct scenarios. The proposed predictor is independent of the scenario in which it will be applied. In the first one, the traffic pattern was synthetically generated following a Poisson distribution and the second one was acquired from a public database. From the results in the synthetic scenario, we have developed two enhancements to be applied to the HMM-based predictor that have been proved to be effective to decrease collision rate and increase seized opportunities. Those enhancements allowed a 45.1% reduction in the collision rate and a 4.9% increase in the seized opportunities if compared to the predictor found in the literature. In this scenario, using a public database, we introduced a new predictor based on Random Forest (RF). The RF predictor was implemented and applied to the same scenarios as the HMM-based predictor. The results show that for scenarios where the PU presents a more stable behavior, both predictors have shown equivalent performances. For scenarios where the PU behavior have high variability, the HMM-based predictor reduced by 10% the collision rate as compared to the RF-based predictor. Nonetheless, the RF-based predictor was able to seize 6.9% more opportunities when compared to the HMM-based predictor.

Keywords: Hidden Markov Model, Opportunity Forecasting, Poisson Distributed Traffic, Cognitive Radio, Opportunistic Spectrum Access, Random Forest, Spectrum Prediction, Spectrum Inference, Machine Learning.

Sumário

1	Introdução	1
1.1	Motivação	2
1.2	Objetivo do Trabalho	3
1.2.1	Contribuição	3
1.2.2	Publicações e Conferências	4
1.3	Estrutura do Documento	4
2	Previsão de Ocupação do Espectro com Aprendizado de Máquina	6
2.1	Modelos de Alocação do Espectro	6
2.2	Compartilhamento de Espectro	8
2.2.1	Arquitetura de Rede	8
2.2.2	Alocação do Espectro	9
2.2.3	Método de Acesso ao Espectro	10
2.3	Sensoriamento do Espectro	11
2.3.1	Detector Baseado em Energia	13
2.4	Previsão de Espectro	13
2.4.1	Processo de Gestão do Canal	14
2.4.2	Classificação dos Algoritmos de Previsão de Espectro	15
2.5	Modelo Escondido de Markov	16
2.5.1	Algoritmo <i>forward</i>	18
2.5.2	Algoritmo <i>backward</i>	19
2.5.3	Previsão utilizando HMM	19
2.5.4	Aprendizado utilizando HMM	20
2.6	Árvores de Decisão e Florestas Aleatórias	21
2.6.1	Árvores de Decisão	22
2.6.2	Agregação de Classificadores	24
2.6.3	Otimização dos Parâmetros e Validação Cruzada	26
2.7	Discussão	27

3	Revisão do Estado da Arte	29
3.1	Seleção dos Trabalhos Relacionados	30
3.1.1	Previsão do Estado do Canal	32
3.1.2	Previsão do Ciclo de Ocupação	35
3.1.3	Previsão do Nível de Potência Recebida	36
3.2	Discussão	37
4	Proposta de Previsão de Ocupação do Espectro	39
4.1	Previsão de Ocupação do Espectro com HMM	39
4.1.1	Composição do Preditor	40
4.1.2	Sensoriamento do Espectro	40
4.1.3	Extração de Tamanhos	41
4.1.4	Treinamento	42
4.1.5	Procedimento de Previsão	44
4.2	Aprimoramento do Preditor com HMM	45
4.2.1	Limite de Treinamento - TL	45
4.2.2	Controle de Treinamento - TC	47
4.3	Previsão de Ocupação do Espectro com RF	48
4.3.1	Treinamento da Floresta Aleatória	48
4.3.2	Previsão Utilizando Florestas Aleatórias	50
4.4	Métricas de Avaliação	50
4.4.1	Classificação da Previsão	50
4.4.2	Classificação dos <i>slots</i>	51
4.5	Métrica de Avaliação Objetiva de Desempenho	53
4.5.1	Motivação	53
4.5.2	Formulação	54
4.6	Discussão	56
5	Resultados com Tráfego Sintético	57
5.1	Metodologia	57
5.2	Previsão de Ocupação com Tráfego Sintético	58
5.2.1	Caracterização do PU	58
5.2.2	Características dos Preditores	60
5.2.3	Treinamento e Seleção do Preditor	60
5.2.4	Resultados da Predição em Tráfego Sintético	64
5.3	Influência da Ocupação do PU nas Previsões	64
5.3.1	Caracterização do PU	65
5.3.2	Características dos Preditores	65

5.3.3	Treinamento e Seleção do Preditor	66
5.3.4	Resultados da Influência da Ocupação do Canal	67
5.4	Discussão	69
6	Resultados com Tráfego Real	71
6.1	Metodologia	71
6.2	Previsão de Ocupação com Tráfego Real	72
6.2.1	Descrição da base DySPAN	72
6.2.2	Canalização e Amostragem	74
6.2.3	Limiar Dinâmico	75
6.2.4	Características dos Preditores	77
6.2.5	Treinamento e Seleção do Preditor	78
6.2.6	Resultados de Previsão com Tráfego Real	85
6.3	Discussão	89
7	Conclusões e Trabalhos Futuros	91
	Referências	93
	Anexo	103
I	Valores de Referência para Escolha do Preditor	104

Lista de Figuras

2.1	Conceito de <i>whitespace</i> e acesso dinâmico ao espectro.	7
2.2	Classificação das técnicas de compartilhamento do espectro.	9
2.3	Ilustração do processo de gestão de canais realizado pelo SU.	14
2.4	Detalhe do cálculo das variáveis <i>forward</i> utilizando o algoritmo <i>forward</i> . . .	18
2.5	Exemplo da representação no plano cartesiano das subáreas e da estrutura da árvore de decisão, para um problema com duas variáveis de entrada. . .	22
2.6	Variável de entrada, variável alvo e conjunto de treinamento para árvore de decisão.	23
2.7	Estratégias de formação de comitês para agregação de modelos individuais de classificação e regressão.	25
2.8	Utilização da validação cruzada no processo de treinamento de um comitê formado pelo processo de ensacamento.	27
4.1	Modelo do sistema de predição.	41
4.2	Exemplo da atuação do extrator de tamanhos nas sequências <i>B</i> e <i>D</i>	42
4.3	Processo de definição da composição do preditor e treinamento.	43
4.4	Quantidade de ocorrências de cada duração da ociosidade entre cinco e oito <i>slots</i>	46
4.5	Quantidade de ocorrência de cada duração da ociosidade entre cinco e oito <i>slots</i>	47
4.6	Exemplo de utilização conjunta de TL+TC, com $\mathcal{S} = 20$	48
4.7	Exemplo de formação das variáveis de treinamento da floresta aleatória a partir da sequência $D_{treinamento}$	49
4.8	Definição de previsão exata, previsão subestimada e previsão sobre-estimada e classificação dos <i>slots</i> após tentativa de uso do SU.	51
4.9	Resultado do compartilhamento do canal entre o PU e o SU.	52
4.10	Motivações para os componentes da métrica MAOD. (1) Distância ponderada do valor ideal de <i>W</i> . (2) Distância ponderada do valor ideal de <i>C</i> . . .	55
5.1	Metodologia de avaliação dos preditores.	58

5.2	Quantidade de ocorrências das durações das ociosidades e dos períodos de ocupação do canal na (a) sequência de treinamento e na (b) sequência de seleção do melhor preditor.	59
5.3	MSE, taxa de colisão e taxa de oportunidades aproveitadas para o preditor padrão, para os preditores utilizando os aprimoramentos TL e TC, individualmente e em conjunto.	61
5.4	MAOD para o cenário em que o PU ocupa o canal em 50% do tempo e $\mathcal{S} = 50$	62
5.5	Taxa de oportunidades aproveitadas e taxa de colisão para cada cenário de ocupação do PU entre 10% e 90%.	68
5.6	Quantidade de <i>slots</i> vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e quantidade de <i>slots</i> não utilizados. (a) visão em proporção e (b) visão em números absolutos.	69
6.1	Metodologia de avaliação dos preditores na base dados pública.	72
6.2	Descrição e exemplo de transmissões dos cenários 0 a 9. Visualização de 150ms (3×50 ms) de cada cenário.	73
6.3	Utilização dos conjuntos de treinamento e teste da base DySPAN.	74
6.4	Divisão dos quatro canais dispostos na banda monitorada.	75
6.5	Cálculo da potência relativa recebida para o canal 3.	76
6.6	Representação do conjunto de treinamento contendo 1.000 arquivos, da divisão proposta e das destinações de cada parte.	78
6.7	Dispersão das diferentes configurações dos preditores em função de C e W. (a) e (c) apresentam todas as configurações possíveis para os cenários 5 e 6. (b) e (d) apresentam as configurações escolhidas ao utilizar a métrica MAOD, para α entre 0 e 1.	79
6.8	Escolha da configuração do melhor preditor em função do valor do α , para os cenários 5 e 6.	81
6.9	Dispersão das diferentes configurações dos preditores em função de C e W. (a), (c) e (e) apresentam todas as configurações possíveis para os cenários 7, 8 e 9. (b), (d) e (f) apresentam as configurações escolhidas ao utilizar a métrica MAOD, para α entre 0 e 1.	83
6.10	Escolha da configuração do melhor preditor em função do valor do α , para os cenários 7 a 9.	84
6.11	Taxa de oportunidades aproveitadas e taxa de colisão para os cenários 5-9.	86

6.12	Quantidade de <i>slots</i> vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e a quantidade de <i>slots</i> não utilizados em cada cenário. (a-b) visão em proporção e (c-d) visão em números absolutos. Valores referentes ao emprego do preditor com HMM.	88
6.13	Quantidade de <i>slots</i> vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e a quantidade de <i>slots</i> não utilizados em cada cenário. (a-b) visão em proporção e (c-d) visão em números absolutos. Valores referentes ao emprego do preditor com RF.	89

Lista de Tabelas

2.1	Características das técnicas de sensoriamento de banda estreita.	12
3.1	Crerios de inclus3o de artigos e trabalhos na revis3o.	31
3.2	Comparativo das caracteristicas dos trabalhos da 3rea.	32
3.3	Classificac3o dos artigos cujo objetivo 3 realizar previs3o da ocupac3o dos canais.	33
5.1	Caracteristicas do cen3rio de simulac3o.	59
5.2	Caracteristicas dos preditores que ser3o avaliados.	60
5.3	Cinco melhores resultados de MAOD para $\alpha = 0,5$ e $\mathcal{S} = 50$	62
5.4	Resultado da modificac3o do peso α e o reflexo na m3trica MAOD. Para $\mathcal{S} = 50$	63
5.5	Desempenho do melhor preditor no conjunto de testes, utilizando $\alpha = 0,5$ e $\mathcal{S} = 50$	64
5.6	Quantidade de amostras em cada cen3rio de ocupac3o do PU.	65
5.7	M3dia de Poisson para cada cen3rio de ocupac3o do canal pelo PU.	65
5.8	Caracteristicas do cen3rio de simulac3o.	66
5.9	Melhor conjunto de par3metros do preditor para cada cen3rio de ocupac3o, com $\alpha = 0,5$	67
6.1	Configurac3o dos filtros aplicados para definic3o do limiar nos Cen3rios 5-9.	77
6.2	Caracteristicas dos preditores com HMM que ser3o avaliados.	77
6.3	Caracteristicas dos preditores com floresta aleat3ria que ser3o avaliados.	78
6.4	Intervalos de α no qual a relac3o W - C obt3m seu maior valor para os cen3rios 5 e 6.	81
6.5	Intervalos de α no qual a relac3o W - C obt3m seu maior valor para os cen3rios 7, 8 e 9.	85
6.6	Melhor conjunto de par3metros do Preditor para os Cen3rios 5-9.	85
I.1	Melhor conjunto de par3metros do Preditor com HMM para os Cen3rios 5 e 6.	105

I.2	Melhor conjunto de parâmetros do do Preditor com RF para os Cenários 5 e 6.	105
I.3	Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 7. . .	105
I.4	Melhor conjunto de parâmetros do Preditor com RF para o Cenário 7. . . .	106
I.5	Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 8. . .	106
I.6	Melhor conjunto de parâmetros do Preditor com RF para o Cenário 8. . . .	106
I.7	Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 9. . .	106
I.8	Melhor conjunto de parâmetros do Preditor com RF para o Cenário 9. . . .	106

Lista de Abreviaturas e Siglas

ARIMA (*Autoregressive Integrated Moving Average* - ARIMA).

C Taxa de Colisão.

CNN (*convolutional neural network* - CNN).

CR Rádio Cognitivo (do inglês, *Cognitive Radio* - CR).

DC Ciclo de Ocupação (do inglês, *Duty Cycle* - DC).

DNN (*Deep Neural Networks* - DNN).

DRL (*Deep Reinforcement Learning* - DRL).

DSA Acesso Dinâmico ao Espectro (do inglês, *Dynamic Spectrum Access* - DSA).

EB Estação Base.

ETS (*Extended Exponential Smoothing* - ETS).

HMM Modelo de Markov Escondido (do inglês *Hidden Markov Model* - HMM).

IoT Internet das Coisas (do inglês, *Internet of Things* - IoT).

ISM *Industrial, Scientific and Medical*.

LSTM (*Long Short-Term Memory* - LSTM).

MAOD Métrica de Avaliação Objetiva de Desempenho.

MAPE Erro Percentual Absoluto Médio (do inglês, *Mean Absolute Percentage Error* - MAPE).

MLP (*MultiLayer Perceptron* - MLP).

MSE Erro Quadrático Médio (do inglês, *Mean Square Error* - MSE).

NN Redes Neurais (do inglês, *Neural Networks* - NN).

OSA Acesso Oportunista ao Espectro (do inglês, *Opportunistic Spectrum Access* - OSA).

PU Usuário Primário (do inglês, *Primary User* - PU).

RF Floresta Aleatória (do inglês, *Random Forest* - RF).

RMSE Erro Quadrático Médio (do inglês, *Root Mean Squared Error* - RMSE).

RNA Rede Neural Artificial.

SS Sensoriamento do Espectro (do inglês, *Spectrum Sensing* - SS).

SU Usuário Secundário (do inglês, *Secondary User* - SU).

TC Controle de Treinamento.

TL Limite de Treinamento.

TL+TC Aplicação conjunta do TL e do TC.

U-NII *Unlicensed National Information Infrastructure*.

W Taxa de Aproveitamento de Oportunidades.

XGBoost (*Extreme Gradient Boosting* - XGBoost).

Capítulo 1

Introdução

Diversos estudos medindo o uso de canais sem fio foram conduzidos no passado [1, 2, 3] e mostram que algumas frequências possuem utilização esporádica ou eventual pelos usuários licenciados (que chamamos de Usuário Primário (do inglês, *Primary User* - PU)). Como resultado direto da estratégia de alocação estática de uso exclusivo de canais, na qual cada serviço tem um canal reservado, poucos canais estão disponíveis para alocação de novos serviços. Aliado à popularização dos dispositivos sem fio, ávidos por maior vazão de dados e conseqüentemente maior largura de banda, há atualmente um grande interesse por novas porções do espectro. Aplicações como Internet das Coisas (do inglês, *Internet of Things* - IoT), telepresença por hologramas, robôs colaborativos e turismo no espaço e no mar profundo são exemplos de aplicações que já impõem desafios de conectividade para as redes 5G em implantação ao redor do mundo. Os desafios de conectividade estão associados à taxa de dados disponível, latência, confiabilidade, disponibilidade e cobertura [4]. Encontram-se em andamento iniciativas para atender as demandas impostas por essas novas aplicações através da especificação de redes que sejam capazes de satisfazer os requisitos das aplicações [5]. Uma das formas de aumentar a taxa de dados disponíveis para as aplicações sem fio é, portanto, melhor aproveitar as frequências subutilizadas através de compartilhamento de canais. A implementação de Rádio Cognitivo (do inglês, *Cognitive Radio* - CR) [6] é alternativa para lidar com a pouca disponibilidade de canais sem fio não alocados, na medida em que permite que os agentes de rede realizem o Acesso Oportunista do Espectro (OSA) [7]. O uso de técnicas de OSA permite a coexistência de outros usuários na mesma frequência sem causar interferências prejudiciais.

A coexistência é alcançada quando usuários não licenciados (chamados, neste contexto, de Usuário Secundário (do inglês, *Secondary User* - SU)) identificam oportunidades de uso em canais licenciados e são capazes de realizar o acesso sem que causem interferência prejudicial aos usuários licenciados. Deste modo, é importante que os SUs possuam mecanismos para identificar adequadamente a utilização do canal pelo PU, de modo que

seja capaz de determinar se o canal está ocupado ou ocioso. Técnicas de sensoriamento do espectro, como a detecção por energia [8], são amplamente utilizadas para determinar o estado de ocupação do canal e mapear o comportamento de utilização do PU.

Modelar o comportamento do PU permite que o SU busque, com melhor eficiência, utilizar o canal sem causar interferências. Ao identificar características do PU que permitam tornar previsível quando (e por quanto tempo) o canal não estará em uso, o SU pode aproveitar o canal para suas próprias transmissões. O SU pode tirar proveito de padrões identificados, conhecimento prévio do PU ou mesmo de técnicas de aprendizado de máquina para decidir quando fazer uso do canal. Esses procedimentos têm o objetivo de instruir o SU o melhor momento de realizar a transmissão no canal e, por isso, são chamados de **técnicas de previsão de ocupação do espectro** ou **técnicas de inferência de ocupação do espectro** [9].

1.1 Motivação

Modelos de inteligência artificial têm sido aplicados com sucesso em diversas áreas do conhecimento como na indústria produtiva [10, 11], saúde [12, 13], linguagens [14], robótica [15], dentre outros. Esses modelos também têm sido utilizados para previsão de espectro, e Ding *et al.* [9] apresentam diversos métodos de aprendizado de máquina empregados com o objetivo de identificar, modelar e prever o comportamento do PU no canal. Neste sentido, técnicas de aprendizado de máquina que se mostrem efetivas em identificar e caracterizar o comportamento do PU no canal podem ser utilizadas por SUs para realizar o Acesso Oportunista ao Espectro (do inglês, *Opportunistic Spectrum Access* - OSA). Para a caracterização do canal é comum que o SU assuma que o PU transmita em um canal dividido em *slots* de tempo [16, 17, 18]. Desta forma, durante o sensoriamento do espectro o SU determina se ele identificou atividade do PU durante o tempo delimitado por um *slot*.

Ao viabilizar o compartilhamento de canais e o uso oportunista, novos serviços podem ser atendidos e implementados. É o caso, por exemplo, da demanda de canais sem fio esperada na implantação das redes móveis de quinta geração (5G), que previam o atendimento de 50 bilhões de dispositivos de Internet das Coisas (do inglês, *Internet of Things* - IoT) em 2020 [19]. Porém, o compartilhamento só é vantajoso para um PU se o SU for capaz de evitar colisões ou interferências.

As previsões de curta duração estimam o estado de apenas um *slot* a frente, permitindo a exploração individual de cada *slot* a partir da previsão realizada. As previsões de curta duração geralmente sofrem de defasagem em CR, já que não há tempo hábil para a reconfiguração necessária do rádio para transmissão [20]. A previsão de longa duração

possibilita a redução na quantidade de trocas de canal necessárias para o SU evitar colisão em cenários com mais de um canal [21]. Esse tipo de previsão é também mais atrativa para aplicações de gerenciamento do espectro que visam o OSA [22, 20] e são indispensáveis na aplicação do DSA [16]. Elias *et al.* [21] sugere uma estratégia que, ao identificar o estado de vários *slots* a frente, um SU pode ajustar o sensoriamento e as transmissões de modo a reduzir o gasto energético e aumentar a quantidade de dados transmitidos de forma oportunista. Motivados pelo claro benefício de se realizar previsões de longa duração e pelo sucesso da aplicação de inteligência artificial em diversas áreas do conhecimento, o objetivo deste trabalho é aplicar técnicas de aprendizado de máquina para previsões de longa duração, de modo a capacitar um SU para coexistir em um mesmo canal com um PU sem causar interferência prejudicial.

1.2 Objetivo do Trabalho

O uso de um preditor baseado em Modelo de Markov Escondido (do inglês *Hidden Markov Model* - HMM) foi proposto por Saad *et al.* [23] para prever o comportamento do PU em uma rede veicular. O preditor proposto pelos autores é capaz de realizar previsões de longa duração no cenário especificado. Os resultados obtidos pelos autores denotam o desempenho do preditor para o cenário específico para qual foi analisado e, portanto, não permitem avaliações quanto a aplicabilidade deste preditor em outros cenários. Por isso, o objetivo deste trabalho é avaliar o emprego do preditor baseado em HMM em diferentes comportamentos do PU para realização de previsão de espectro de longa duração, bem como propor alternativas para adaptação dos preditores com foco na redução de colisões e no incremento do aproveitamento de oportunidades.

Outro ponto que queremos investigar é a influência da ocupação do canal pelo PU no desempenho desse modelo de preditor. Akbar *et al.* [24] investigou o uso do preditor com HMM em um canal onde o PU ocupava o canal por 50% do tempo e Saad *et al.* [23] avaliaram o preditor com HMM para previsões de longa duração em canais cuja ocupação variavam entre 20% e 70%. Estes resultados indicam que em canais com maior ocupação (menor disponibilidade de oportunidades) o desempenho deste preditor é melhor do que em canais com menor ocupação. Considerando os resultados acima, este trabalho tem como objetivo secundário avaliar se as condições dos trabalhos correlatos se aplicam aos cenários a serem avaliados.

1.2.1 Contribuição

Deste modo, as contribuições deste trabalho são:

- Apresentar uma avaliação do preditor com HMM para múltiplos *slots* a frente para dois cenários: um cenário sintético onde o comportamento do PU é ditado por uma distribuição de Poisson; e um cenário com dados reais do monitoramento de canais obtidos de uma base pública.
- Avaliar o comportamento do preditor com HMM para múltiplos *slots* a frente quando submetido a canais com diferentes níveis de ocupação pelo PU.
- Avaliar a influência do formato do treinamento no desempenho do preditor elaborado e propor modificações no formato do treinamento, com melhoria significativa de desempenho.
- Avaliar, no contexto de previsão ocupação de canais para múltiplos *slots* a frente, o desempenho da utilização do algoritmo *Random Forest*. No melhor do nosso conhecimento, não houve, na literatura científica, a utilização do *Random Forest* para este cenário.
- Propor um mecanismo configurável de escolha do preditor baseado no desempenho obtido na etapa de treinamento.

1.2.2 Publicações e Conferências

Parte dos resultados obtidos neste trabalho foram publicados/aceitos nas seguintes conferências:

- *Hidden markov model spectrum predictor for poisson distributed traffic, International Conference on Wireless and Mobile Computing, Networking and Communications - WIMOB 2020*, outubro de 2020. (Publicado)
- *On the Performance of Hidden Markov Model Spectrum Opportunity Forecast on Limited Observed Channel Activity, The Ninth International Symposium on Computing and Networking - CANDAR 2021*, novembro de 2021. (Aceito)

Como há resultados deste trabalho que não foram submetidos para conferências, pretendemos consolidar estes resultados em um artigo de revista para submissão futura.

1.3 Estrutura do Documento

O restante deste trabalho está organizado da seguinte forma. O Capítulo 2 apresenta os conceitos relacionados a aplicação de aprendizado de máquina para previsão de ocupação de espectro. Nesse capítulo apresentamos também os dois modelos de inteligência artificial

que serão avaliados neste trabalho: HMM e RF. O Capítulo 3 apresenta a metodologia de pesquisa utilizada para a revisão do estado da arte e para seleção dos trabalhos a serem revisados. Apresenta também as características principais dos trabalhos selecionados e uma classificação com base na característica de interesse da previsão. O Capítulo 4 sintetiza a proposta deste trabalho, as métricas de avaliação e a proposta de métrica de escolha da configuração dos preditores. O Capítulo 5 apresenta os resultados obtidos da aplicação do preditor com HMM em um cenário em que o comportamento do PU foi gerado de forma sintética. Esse capítulo também apresenta a avaliação das propostas de aprimoramento do treinamento do preditor com HMM e uma avaliação da influência da ocupação do canal pelo PU sobre a qualidade das previsões realizadas. O Capítulo 6 a avaliação dos preditores com HMM e com RF quando aplicados a um cenário com tráfego real. Por fim, o Capítulo 7 apresenta o panorama dos resultados alcançados neste trabalho e indica os trabalhos futuros.

Capítulo 2

Previsão de Ocupação do Espectro com Aprendizado de Máquina

O uso compartilhado de canais sem fio tem surgido como alternativa à baixa disponibilidade de canais para novos serviços. Neste contexto, o sensoriamento é crucial para obter informações de ocupação dos canais e guiar as tentativas de transmissão, com o foco em minimizar colisões entre os usuários que estão compartilhando o canal. Porém o sensoriamento só fornece ao nó de rede uma visão da ocupação atual, sem fornecer nenhum indicativo sobre a ocupação futura. Para suprir esta necessidade, algoritmos de previsão de ocupação do espectro são empregados na tentativa de prever a ocupação do canal, para fornecer ao nó de rede instrução de quanto tempo ele pode transmitir sem que suas transmissões interfiram com outras. Métodos de aprendizado de máquina têm sido utilizados para capturar as complexas dependências no comportamento do PU e guiar as decisões do SU quanto ao momento correto de iniciar e terminar suas transmissões. Neste capítulo mostraremos como o modelo de alocação do espectro e o compartilhamento de espectro podem permitir a coexistência harmônica entre diferentes usuários em um mesmo canal. Através do sensoriamento do espectro um SU pode identificar a presença do PU no canal e aplicar técnicas de previsão do espectro para evitar colisões. Por fim, mostraremos duas técnicas de aprendizado de máquina que serão utilizadas para previsão de espectro no escopo deste trabalho, explorando o mecanismo de aprendizado e previsão de cada uma delas.

2.1 Modelos de Alocação do Espectro

O controle do uso do espectro tem como objetivo primário garantir que o usuário detentor do direito de uso não tenha interferência em suas transmissões [25]. O uso de cada canal é usualmente controlado por um órgão regulador, que atua também como fiscal, garantindo

que os usuários operem seus transmissores e receptores de acordo com as regras por ele estabelecidas. A cessão do direito de uso a um usuário denominamos alocação do espectro. O órgão regulador pode definir faixas de frequência de livre acesso para viabilizar serviços compartilhados.

Existem dois modelos de alocação de espectro: estática e dinâmica [26]. O modelo atual de uso do espectro aloca estaticamente um ou mais canais para determinado serviço em uma região. Por ser uma alocação estática e para evitar interferência, comunicações distintas são alocadas em canais diferentes com previsão de banda de guarda, que são utilizadas para diminuir interferência no canal adjacente. Uma vez alocado, somente o serviço destinado a um determinado canal pode utilizá-lo, mesmo que não o faça em todo o tempo. Diversos estudos têm mostrado que a utilização da porção licenciada do espectro é baixa tanto espacialmente quanto no tempo [27, 28, 29, 30]. Existem faixas chamadas não licenciadas, como a banda ISM (*Industrial, Scientific and Medical*) e U-NII (*Unlicensed National Information Infrastructure*), que são compartilhadas por diversos serviços concorrentemente.

Essas características da alocação estática têm motivado, ao redor do mundo, modificações na legislação para possibilitar o uso de técnicas de compartilhamento de canais, onde dois ou mais serviços podem coexistir no mesmo canal. Em canais compartilhados é possível fazer uso de técnicas de Acesso Dinâmico ao Espectro (do inglês, *Dynamic Spectrum Access - DSA*) que permitam o melhor aproveitamento do espectro através de maior flexibilidade no acesso [7]. Através do DSA um nó de rede poderia dinamicamente modificar seu canal de utilização ao perceber, com base em um conjunto de informações, interferência no canal atual.

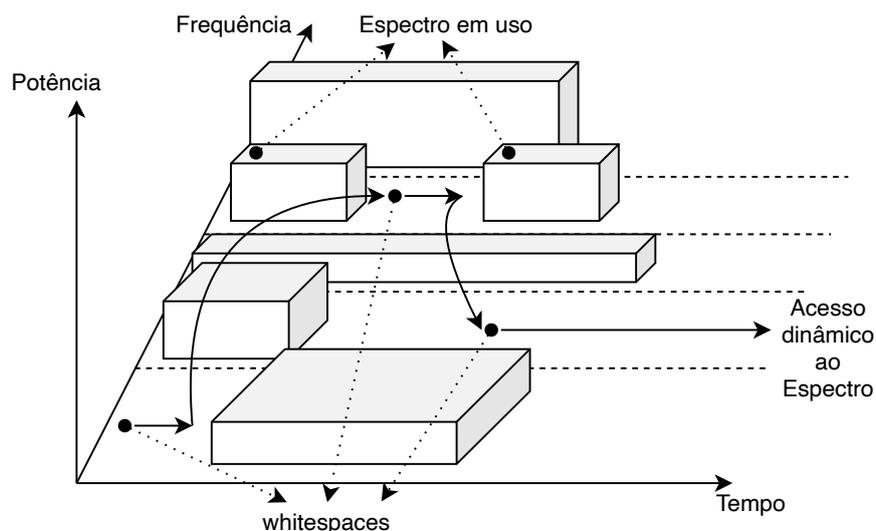


Figura 2.1: Conceito de *whitespace* e acesso dinâmico ao espectro.

Chamamos de Usuário Primário (do inglês, *Primary User* - PU) o usuário licenciado para uso do canal. Na Figura 2.1, o uso primário do canal está representado pela potência de utilização em cada faixa de frequência delimitada [31]. Em cenários de compartilhamento de canal, usuários licenciados têm prioridade para transmissões e não devem ser afetados por usuários não licenciados. No modelo de compartilhamento de canais, um Usuário Secundário (do inglês, *Secondary User* - SU) é aquele que não detém licença para uso do canal, mas o faz de forma dinâmica. Na Figura 2.1, denominamos *whitespaces*, os períodos em que os canais não estão em utilização pelo PU. Dessa forma, os *whitespaces* são potenciais oportunidades de utilização pelo SU.

2.2 Compartilhamento de Espectro

Com o objetivo de melhorar a disponibilidade de canais sem fio para novos serviços, o compartilhamento do espectro tem papel preponderante no aumento da oferta deste recurso escasso. Técnicas de compartilhamento de espectro podem ser usadas para que um canal seja compartilhado por serviços compatíveis sem que aconteça interferência prejudicial entre eles e todos os serviços sejam atendidos dentro de parâmetros preestabelecidos. Especialmente em casos em que as características de tráfego sejam dinâmicas e assimétricas, o compartilhamento cooperativo tem se mostrado benéfico [32]. Contudo, para uma operação benéfica e equilibrada é necessário haver uma relação de confiança entre os operadores, garantindo que o compartilhamento seja justo, transparente e que se atinja os níveis de serviços estabelecidos.

A Figura 2.2 mostra a classificação encontrada na literatura das três principais características: arquitetura de rede, alocação e métodos de acesso ao espectro [32]. A arquitetura de rede pode ser centralizada ou distribuída. O método de alocação do espectro pode acontecer de forma cooperativa ou não cooperativa. Por fim, o método de acesso pode ser exclusivo dinâmico, acesso aberto ou hierárquico, sendo que este último pode ser realizado em três abordagens: *overlay*, *underlay* ou *interweave* [33]. Essas características serão detalhadas a seguir.

2.2.1 Arquitetura de Rede

No que tange a arquitetura de rede, o compartilhamento pode ser centralizado ou distribuído. Na arquitetura centralizada o espectro pode ser compartilhado através de uma base de dados de informações de disponibilidade dos canais [34]. Um nó central chamado de Estação Base (EB) coordena a alocação de recursos e os procedimentos de acesso aos canais. Quando um nó precisa transmitir algo ele solicita à EB a alocação de um canal

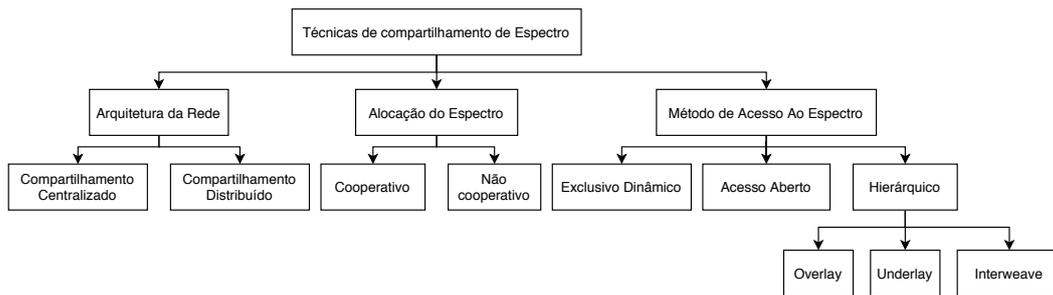


Figura 2.2: Classificação das técnicas de compartilhamento do espectro.

para esta comunicação, que pode, de maneira justa, realizar a alocação dos recursos disponíveis entre os usuários requisitantes. A EB também é capaz de maximizar a utilização da capacidade da rede e a eficiência espectral já que tem uma visão global das necessidades dos usuários e dos canais disponíveis. As informações de ocupação podem ser obtidas por sensoriamento na própria EB ou em cooperação com os nós da rede. A arquitetura centralizada é utilizada para alocação de recursos, por exemplo, em redes Wi-Fi e em redes 4G. Por outro lado, o controle de alocações de recursos exige um canal dedicado a controle, onde a EB se comunica com os nós da rede, e a troca de vários pacotes de sinalização com este propósito. Na arquitetura distribuída, os nós de rede são responsáveis pela obtenção dos dados de ocupação através do seu próprio processo de sensoriamento ou da comunicação prévia com outros nós, para tomar a decisão de acesso ao espectro. Esta arquitetura é utilizada usualmente em locais desprovidos de infraestrutura para implementação do modelo centralizado. A troca de pacotes para controle é consideravelmente menor do que no modelo distribuído, porém a complexidade da decisão de quais canais acessar é maior. A arquitetura distribuída é aplicada em redes *ad hoc* e redes de sensores.

2.2.2 Alocação do Espectro

Para realizar alocação do espectro um nó pode se comportar de duas formas: não cooperativa e cooperativa [34]. A forma não cooperativa de alocação do espectro assume que cada nó, individualmente, realiza o sensoriamento dos canais de interesse e decide de forma local qual canal irá acessar. Neste cenário apenas as informações obtidas pelos próprios nós são utilizadas, evitando gasto de energia com a troca de pacotes de controle. Por outro lado, por conta da visão possivelmente limitada da observação de cada nó, a utilização do espectro é reduzida. A forma cooperativa pode ser implementada empregando-se a arquitetura centralizada ou distribuída [9]. No primeiro caso a cooperação ocorre através das informações recebidas da EB. Na arquitetura distribuída as informações podem ser disseminadas nó a nó para que cada um monte sua própria visão da rede.

2.2.3 Método de Acesso ao Espectro

Quanto ao método de acesso utilizado, podemos dividir as técnicas de compartilhamento em três grupos: acesso exclusivo dinâmico, acesso aberto e acesso hierárquico [32]. No modelo de acesso exclusivo dinâmico, um canal alocado para um PU pode ser vendido ou alugado para um outro PU [35]. Neste modelo o PU cede seu direito de uso exclusivo para outro SU com alguma contrapartida, em locais subutilizados ou por um determinado período. No modelo de acesso aberto os usuários têm acesso irrestrito ao espectro e pode ser utilizado por qualquer aplicação ou serviço. Nestes casos, podem existir certas regras de utilização impostas por algum órgão regulador de cada localidade. No modelo hierárquico há três abordagens para o compartilhamento do espectro: *underlay*, *overlay* e *interweave*. Este modelo é chamado hierárquico por pressupor preferência de acesso ao PU.

Na abordagem *underlay*, PUs e SUs podem utilizar a mesma frequência ao mesmo tempo desde que a interferência gerada pelo SU a cada PU esteja abaixo de um limite permitido [36, 37, 38, 39]. Técnicas de processamento de sinais e de controle de potência pelo usuário secundário para manter a interferência abaixo de um limite aceitável durante suas transmissões [38, 40, 41]. Em geral os SUs precisam de informações que possam ser utilizadas para controle da interferência, como informações acerca do uso do canal ou da localização do PU.

Na abordagem *overlay*, PUs e SUs também podem utilizar a mesma frequência simultaneamente, porém assume-se que o SU possui informação sobre as mensagens e o comportamento do PU. Esse conhecimento sobre as mensagens e o protocolo do PU pode ser utilizado para minimizar ou eliminar a interferência percebida pelos PUs e SUs [42, 43]. Ainda, os SUs podem utilizar parte da energia para transmitir cooperativamente com o PU e o restante da energia para suas próprias comunicações. O ganho cooperativo oferecido ao PU através da comunicação cooperativa compensa a interferência causada pela transmissão realizada pelos SUs [44].

Na abordagem *interweave*, SUs exploram a ociosidade do PU em tempo e em frequência para suas comunicações, ou seja, o SU somente utiliza o espectro quando o PU não está utilizando [45, 46]. Identificar corretamente espaços de ociosidade do PU permite que o SU possa transmitir com a potência necessária para sua comunicação sem interferir na comunicação do PU. Porém, SU com apenas um rádio não consegue transmitir e monitorar o canal simultaneamente, podendo causar interferência no PU se este iniciar uma transmissão durante uma transmissão do SU. Assim, prever adequadamente o início e o fim das oportunidades faz com que o SU maximize sua comunicação sem causar interferência no PU.

Em qualquer dos modelos de compartilhamento adotado, a etapa essencial e anterior

é a obtenção de dados da atividade do canal a ser compartilhado. A esta etapa denominamos sensoriamento do espectro ou sensoriamento do canal sem fio, que definimos de detalhes na seção seguinte.

2.3 Sensoriamento do Espectro

O padrão IEEE Std 1900.1-2019 [47], publicado pelo IEEE em 2019, visa prover definições concisas dos termos chave em tecnologias avançadas de sistemas de rádio e técnicas avançadas de gerenciamento do espectro. Nele, Sensoriamento do Espectro (do inglês, *Spectrum Sensing* - SS) é definido de duas formas:

1. O ato de categorizar e avaliar sinais de rádio com o propósito de obter informações.
2. O ato de medir informações indicativas de ocupação do espectro (as informações podem incluir faixas de frequência, nível de potência dos sinais, largura de banda, informação de localização, etc.) no contexto de radiofrequência. Sensoriamento do espectro pode incluir a determinação de como o espectro é utilizado.

A confiabilidade da etapa de sensoriamento está diretamente relacionada à técnica de sensoriamento de espectro utilizada. É através do sensoriamento que os SUs obtêm informação de ocupação de determinado canal, podendo utilizar essa informação para guiar o acesso ao canal. As técnicas podem ser classificadas em dois grupos [47]: sensoriamento de **banda estreita** e sensoriamento de **banda larga**. As técnicas de sensoriamento de banda estreita pressupõem que o SU conhece a largura de banda e a frequência central utilizada pelo PU nas suas comunicações, de modo que lhe permita configurar a obtenção das informações apenas do canal de interesse. Neste contexto, apenas uma pequena porção do espectro é analisada com o intuito de determinar a ocupação daquele canal. As técnicas de sensoriamento de banda larga, por sua vez, analisam uma porção muito maior do espectro, obtendo informações de vários canais consecutivos, não precisando conhecer como os PUs estão distribuídos naqueles canais.

Podemos listar como técnicas de sensoriamento de banda estreita a detecção por energia [48, 49, 50, 51, 52, 53, 54, 55], detecção por filtro casado [56, 57, 58, 59], detecção de característica ciclo-estacionária [60, 61, 62, 63, 64, 65], detecção baseada em covariância [66, 67, 68, 69, 70, 71, 72], detecção baseada em autovalor [73, 74, 75] e detecção baseada em forma de onda [76]. Em geral as técnicas de sensoriamento de banda estreita necessitam de um tempo de sensoriamento menor do que as técnicas de banda larga, já que precisam analisar uma porção menor do espectro. Pelo mesmo motivo as primeiras, em geral, apresentam um menor consumo de energia do que as últimas.

Tabela 2.1: Características das técnicas de sensoriamento de banda estreita.

Características	Técnicas de Sensoriamento de Banda Estreita					
Método	Detector por Energia	Deteção por Filtro Casado	Deteção de Característica Ciclo-Estacionária	Deteção Baseada em Autovalor	Deteção Baseada em Covariância	Deteção Baseada em Forma de Onda
Complexidade	Baixa	Média	Alta	Baixa	Baixa	Média
Requer Informação do Sinal?	Não	Sim	Sim	Sim	Não	Sim
Tempo de Sensoriamento	Extremamente Baixo	Baixo	Alto	Baixo	Médio	Baixo
Custo	Extremamente Baixo	Baixo	Alto	Médio	Muito Baixo	Baixo
Confiabilidade	Extremamente Baixa	Muito Alta	Alta	Muito Baixa	Alta	Baixa
Ponto Fraco	Ruído Aleatório	Requer Informação do Sinal	Requer Informação do Sinal	Requer Informação do Sinal	Sinais Não Correlacionados	Requer Informação do Sinal

Apesar de importante campo de pesquisa existente com o sensoriamento de banda larga, este tema não será abordado no escopo deste trabalho já que o foco aqui é observar cada canal individualmente com o objetivo de identificar oportunidades de uso compartilhado. A Tabela 2.1 apresenta as principais características das técnicas de sensoriamento de banda estreita existentes [77]. Informações como formato do pacote, formato do pulso e modulação utilizados pelo PU estão dificilmente disponíveis para o SU dada a grande variedade de aplicações sem fio existentes. Neste cenário, a exigência das técnicas de Deteção por Filtro Casado, Deteção de Característica Ciclo-Estacionária, Deteção Baseada em Autovalor e Deteção Baseada em Forma de Onda de informações prévia do sinal do PU impossibilitam sua utilização nestes cenários. Neste trabalho, consideramos que apenas a informação da ocupação, obtida através do sensoriamento realizado individualmente por cada SU, está disponível sobre o PU. As opções de sensoriamento disponíveis dadas as restrições impostas são o Detector por Energia e a Deteção Baseada em Covariância. Por conta de a Deteção Baseada em Covariância apresentar um tempo de sensoriamento ligeiramente maior e seu desempenho degradar para sinais não correlacionados, o que representaria uma restrição importante ao tipo de usuário primário que poderia ser detectado, optamos neste trabalho por utilizar o detector por Energia nas implementações onde o sensoriamento se fez necessária. Esta escolha se justifica, ademais, por conta do Detector por Energia ter seu ponto fraco minimizado com a aplicação de limiares dinâmicos [50, 54, 52], aumentando significativamente a performance da deteção em cenários de ruído aleatório. Na sequência detalhamos o modelo teórico desse detector.

2.3.1 Detector Baseado em Energia

Nesta seção apresentamos o modelo teórico do detector baseado em energia, com base do detector apresentado em [78]. Esse método não requer conhecimento prévio do PU e utiliza a energia do sinal recebido no SU como parâmetro para decidir se há presença ou não do PU. Considere que duas hipóteses onde H_0 é verdadeira quando não há presença do PU no canal e H_1 é verdadeira quando há presença do PU no canal. Podemos definir o detector baseado em energia da seguinte maneira:

$$E(y) = \frac{1}{N} \sum_{n=1}^N |y_n|^2, \quad (2.1)$$

onde N é o tamanho da amostra de dados, y é um vetor $N \times 1$ do tipo $y = [y_1, \dots, y_N]$ e $E(y)$ é a energia do sinal. Sendo λ um limiar predefinido, podemos definir o teste estatístico de ocupação do canal $H(E(y))$ como:

$$H(E(y)) = \begin{cases} H_0 & \text{se } E(y) < \lambda, \\ H_1 & \text{se } E(y) \geq \lambda. \end{cases} \quad (2.2)$$

A Equação (2.2) é utilizada para a decisão, com base na energia do sinal calculada na Equação (2.1). Caso a energia do sinal $E(y) \geq \lambda$ considera-se que há presença do PU. Caso $E(y) < \lambda$ considera-se o PU não está utilizando o canal naquele instante.

Dado que a cada N amostras o detector baseado em energia pode determinar a ocupação do canal analisado. O tempo necessário para se obter as N amostras é denominado janela de observação. Caso o sensoriamento seja executado de forma contínua, teremos uma sequência de saída do detector contendo as ocupações em cada um das janelas de observação do canal, ou seja, $\{H_0, H_1, H_1, H_0\}$ representaria um exemplo de sequência na saída do detector.

2.4 Previsão de Espectro

Técnicas de previsão de espectro auxiliam o SU na decisão de acesso ao canal, de modo a evitar colisão com o PU. Em um cenário de compartilhamento do canal, o SU busca determinar o comportamento do PU de forma a ajustar suas transmissões nos momentos em que o PU não está utilizando o canal. Para atingir esse objetivo o SU executa o processo de gestão do canal compartilhado que será detalhado a seguir.

2.4.1 Processo de Gestão do Canal

No contexto de compartilhamento de um canal sem fio discutido na Seção 2.2, o SU é o responsável gerir a utilização do canal para identificar as oportunidades e realizar suas transmissões sem causar interferências nas comunicações do PU. O processo de gestão dos canais realizado pelo SU está ilustrado na Figura 2.3 e consiste em quatro passos [31]: sensoriamento, decisão, compartilhamento e mobilidade.

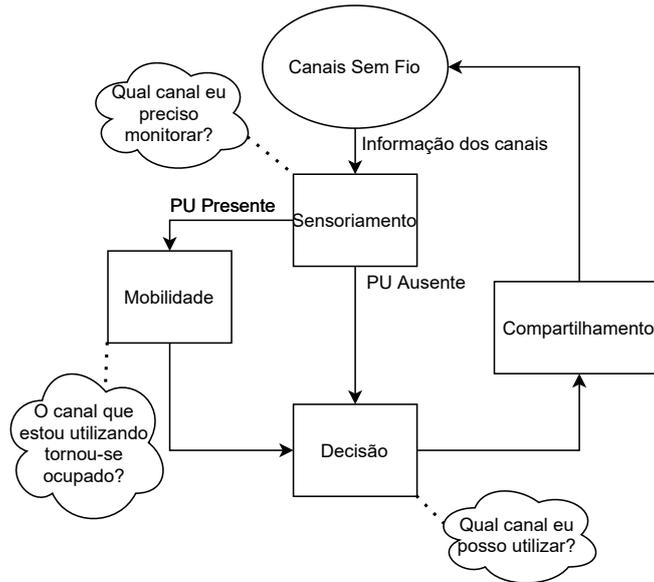


Figura 2.3: Ilustração do processo de gestão de canais realizado pelo SU.

No **Sensoriamento**, um SU pode alocar somente uma porção não utilizada do espectro. Para tanto, um SU deve monitorar as bandas disponíveis, capturar informação e detectar os *whitespaces*. Na **Decisão**, baseado na disponibilidade dos canais, o SU pode alocar um canal. Esta alocação não depende unicamente da disponibilidade do espectro, mas é determinada também com base em políticas internas (e também externas, se houverem). No **Compartilhamento**, por possivelmente existir mais de um SU tentando acessar um determinado canal, os vários SUs devem se coordenar para prevenir que dois deles colidam ao tentar utilizar uma mesma porção do espectro. Na **Mobilidade**, os SUs são considerados como visitantes no espectro. Assim, se uma porção específica do espectro em uso é requisitada pelo PU, a comunicação entre os SUs deve continuar em outra porção não ocupada da banda.

No processo de gestão do canal executado pelo SU, pode-se obter benefício de mecanismos de previsão na etapa de sensoriamento, etapa de decisão e na etapa de mobilidade. Também é possível aplicar mecanismos de previsão na etapa de compartilhamento, apesar de ser pouco comum na literatura [79].

2.4.2 Classificação dos Algoritmos de Previsão de Espectro

Apesar de a ocupação atual do canal fornecer parâmetros importantes para um SU no que diz respeito à ocupação do canal, esta não fornece informações suficientes para realizar o acesso oportunista de forma a evitar interferências com o PU. Neste contexto, várias técnicas de previsão têm sido empregadas no sentido de obter uma estimativa da ocupação do canal em momentos futuros [9], utilizando algoritmos de inferência (*Spectrum Inference*). Os autores em [9] apresentam os tipos de algoritmos que têm sido utilizados como mecanismos de previsão de ocupação do canal, estruturando uma taxonomia. Esses algoritmos estão divididos em três grandes tipos: algoritmos espectrais, algoritmos temporais e algoritmos espaciais. O primeiro tipo agrupa algoritmos que buscam prever a ocupação não apenas de um canal, mas de um conjunto de canais ao longo do tempo e a relação de ocupação entre eles. Usualmente chamado de cenário multicanal, estão disponíveis pelo menos dois canais que podem ser analisados e utilizados pelo SU. O segundo grupo está baseado na modelagem temporal da representação da ocupação do canal, ou seja, uma série temporal, geralmente binária, representa o estado do canal em cada momento. Nesta modelagem todas as análises disponíveis para séries temporais se aplicam, já que a representação é semelhante. O terceiro grupo utiliza informações de localidade para definir a ocupação do canal, de modo que um canal pode estar ocupado em um dado local e ocioso em outro devido ao desvanecimento ou mesmo à diretividade do conjunto de antenas dos transmissores.

Diversas técnicas de aprendizado de máquina tem sido utilizadas para realizar previsão de espectro [9]. HMM tem sido considerada uma alternativa para realizar previsão de espectro por sua sólida base estatística e sua capacidade de modelar sistemas variantes no tempo de forma eficaz [23]. Porém, os modelos construídos com base em HMMs são sensíveis a variações no conjunto de treinamento, especialmente quando o conjunto de treinamento contém pontos fora da curva (*outliers*) [80]. Em aprendizado de máquina, os modelos formados por comitê normalmente apresentam melhor desempenho e são menos afetados por sobre-ajuste (*overfitting*) e pontos fora da curva (*outliers*). Em especial, a floresta aleatória (que é um modelo de comitê no qual seus modelos individuais são árvores de decisão) apresenta melhor desempenho do que a utilização de árvores de decisão individualmente [81]. Ao selecionar aleatoriamente as variáveis em cada nó, a correlação entre as árvores de decisão que compõem a floresta aleatória é reduzida. Deste modo, uma floresta aleatória está menos susceptível a problemas de aprendizado como o sobre-ajuste e pontos fora da curva. Nas próximas seções apresentaremos o modelo teórico do modelo escondido de Markov e da floresta aleatória, e como estes dois mecanismos são utilizados para aprendizado e previsão.

2.5 Modelo Escondido de Markov

Andrey Markov introduziu o conceito do modelo de Markov nos primeiros anos do século 20 [82]. Nas décadas de 60 e 70, Leonard E. Baum *et al.* [83, 84, 85, 86, 87] publicaram vários artigos utilizando a estrutura proposta por Markov. Em 1989 L. R. Rabiner [88] publicou um tutorial com detalhes práticos da aplicação dos métodos propostos por Leonard E. Baum *et al.*, incluindo a descrição da aplicação dos métodos em diversos problemas em reconhecimento de discurso.

Em [89] os autores analisam 146 artigos publicados que aplicam técnicas baseadas em algum dos vários tipos do Modelo de Markov Escondido (do inglês *Hidden Markov Model* - HMM) existentes. Neste trabalho pontuam que HMMs têm sido utilizadas em diversas áreas do conhecimento como reconhecimento de voz, reconhecimento de atividade humana, bioinformática, musicologia, desgaste de ferramenta, processamento de dados e análise de redes [89]. Reconhecimento de voz e reconhecimento de atividade humana respondem por metade dos artigos analisados. Análise de redes conta com 6% dos artigos. Apesar da baixa representação, o potencial desta técnica para esta área de aplicação é o seu baixo custo computacional para a solução do problema se comparada com outras técnicas tradicionalmente utilizadas como Redes Neurais (do inglês, *Neural Networks* - NN) [9].

Uma HMM é uma estrutura matemática simples que permite modelar um sistema variante no tempo. Uma HMM pode ser definida como $\lambda = (\pi, A, B)$, onde π representa o vetor probabilidade do estado inicial e é definido [9] como

$$\pi = [\pi_i] = P(q_t = s_i), 1 \leq i \leq N, \quad (2.3)$$

onde $S = \{s_1, s_2, \dots, s_N\}$ denota os N estados da cadeia de Markov e $q_t \in S$ representa o estado em um instante de tempo t . Para uma HMM com N estados, temos que $\pi = [\pi_1 \pi_2 \dots \pi_N]$ e esse vetor satisfaz as duas propriedades a seguir: $0 \leq \pi_i \leq 1$ e $\sum_{i=1}^N \pi_i = 1$. O vetor π resultante armazena os valores das probabilidades de que a HMM inicie no estado i , ou seja, π_i é a probabilidade de uma dada HMM iniciar no estado i .

A matriz $A = [a_{ij}]$ é a matriz de transição de tamanho $N \times N$, que define a probabilidade de mudança de um estado para outro, formulado como:

$$a_{ij} = P(q_t = s_j | q_{t-1} = s_i), 1 \leq i, j \leq N. \quad (2.4)$$

O estado atual q_{t-1} da HMM é s_i , a probabilidade de transição para o estado s_j no instante de tempo seguinte t é dada pelo elemento a_{ij} da matriz A . Para cada estado de origem i , temos que $\sum_{j=1}^M a_{ij} = 1$.

Por fim, a matriz de probabilidade de emissão ou observação é dada por $B = [b_{ik}]$.

Essa matriz define a probabilidade de produzir diferentes valores observados estando em um dos N estados e é dada por:

$$b_{jk} = P(o_t = v_k | q_t = s_j), 1 \leq j \leq N, 1 \leq k \leq M, \quad (2.5)$$

onde $V = \{v_1, v_2, \dots, v_M\}$ representa o espaço contendo M símbolos e o_t é o valor observado no instante t . Dado que a HMM está no estado $q_t = s_j$, a probabilidade de ser observado o símbolo v_k no instante t é b_{jk} . A matriz B tem tamanho $N \times M$. Para cada estado j , temos que $\sum_{k=1}^M b_{jk} = 1$.

Uma HMM pode ser do tipo discreta ou contínua no tempo. Uma HMM discreta no tempo tem suas transições definidas a cada porção definida de tempo, que chamaremos neste contexto de *slot*. A cada *slot* a matriz de probabilidade de transição é consultada para definir a probabilidade de mudança de estado na mudança para o *slot* seguinte, e não há transição de estado durante a duração do *slot*. Uma HMM contínua no tempo a transição pode ocorrer a cada momento e não apenas na transição entre *slots*.

Três problemas fundamentais estão associados ao modelo de Markov.

- Prever: quando uma HMM λ e uma sequência de observação O são conhecidas, como calcular a probabilidade da sequência de observação $P(O|\lambda)$?
- Decifrar: quando uma HMM λ e uma sequência de observação O são conhecidas, como achar a sequência de estados escondidos que melhor representa a sequência de observação O ?
- Aprender: quando uma sequência de observação O é conhecida, como achar os parâmetros da HMM λ que maximizem a probabilidade da sequência de observação $P(O|\lambda)$?

A previsão é utilizada para determinar a probabilidade de uma sequência de observação O , dado o conjunto de parâmetros λ . Neste sentido, a previsão pode ser utilizada para determinar qual HMM treinada entre um conjunto σ é a mais provável, dada uma sequência de observação. Decifrar é o processo realizado para conhecer quais estados escondidos melhor explicam a observação O de uma HMM λ . No escopo deste trabalho este processo não será utilizado. O aprendizado, também chamado de treinamento, é utilizado para recalcular os parâmetros (π, A, B) de uma HMM com base em uma sequência de observação O .

A seguir, detalharemos os algoritmos *forward* e *backward*, que serão utilizados como base para a solução dos dois problemas de interesse deste trabalho, a saber, a previsão e o aprendizado. Para a previsão aplica-se apenas o algoritmo *forward*. Para o aprendizado, aplica-se conjuntamente os algoritmos *forward* e *backward* em conjunto com um método de maximização de probabilidade [88].

2.5.1 Algoritmo *forward*

Considere que uma sequência de observação de tamanho T é representada por $O = (o_1, o_2, \dots, o_{T-1}, o_T)$. Seja $S = \{s_1, s_2, \dots, s_N\}$. Definimos a variável *forward* $\alpha_i(t)$ como

$$\alpha_i(t) = P(O, q_t = s_i | \lambda). \quad (2.6)$$

A variável $\alpha_i(t)$ pode ser calculada recursivamente da seguinte forma:

1. Início - Cálculo da probabilidade do estado inicial para cada um dos possíveis N estados escondidos

$$\alpha_i(1) = \pi_i \quad \text{onde } 1 \leq i \leq N. \quad (2.7)$$

2. Indução - Cálculo de $\alpha_j(t+1)$, utilizando a probabilidade de transição do estado i para o estado j , a_{ij} , e a probabilidade de observação do símbolo o_{t+1} no estado j . Podemos denotar como:

$$\alpha_j(t+1) = \sum_{i=1}^N \alpha_i(t) a_{ij} b_{jo_{t+1}} \quad \text{para } 1 \leq j \leq N \text{ e } 1 \leq t \leq T-1. \quad (2.8)$$

Ao final deste processo todas as variáveis até o tempo $T-1$ indicadas na Figura 2.4 estarão calculadas.

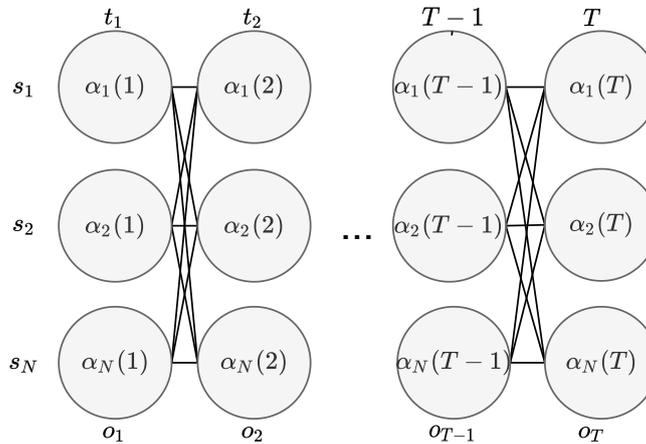


Figura 2.4: Detalhe do cálculo das variáveis *forward* utilizando o algoritmo *forward*.

3. Término - Cálculo de $P(O|\lambda)$ cada um dos elementos

$$P(O|\lambda) = \sum_{i=1}^N \alpha_i(T), \quad (2.9)$$

onde $\alpha_i(t)$ representa a probabilidade de uma sequência terminar no estado $s_i \in S$ no tempo t , dada uma sequência de observação O .

2.5.2 Algoritmo *backward*

O procedimento que utilizamos para o algoritmo *forward* também pode ser utilizado na ordem inversa. Esse procedimento é conhecido como algoritmo *backward*. A variável *backward* pode ser definida como:

$$\beta_i(t) = P(o_{t+1}o_{t+2}\dots o_T, q_t = s_i | \lambda). \quad (2.10)$$

1. Início - Cálculo da probabilidade do estado inicial para cada um dos possíveis N estados escondidos

$$\beta_i(T) = 1 \quad \text{para } 1 \leq i \leq N. \quad (2.11)$$

2. Indução - Cálculo de $\beta_i(t)$, utilizando a probabilidade de transição do estado i para o estado j , a_{ij} , e a probabilidade de observação do símbolo o_t no estado j . Podemos denotar como:

$$\beta_t(j) = \sum_{i=1}^N \beta_j(t+1) a_{ij} b_{j o_t} \quad \text{para } 1 \leq j \leq N \text{ e } 2 \leq t \leq T-1. \quad (2.12)$$

3. Término - Cálculo de $P(O|\lambda)$ cada um dos elementos

$$P(O|\lambda) = \sum_{i=1}^N \beta_i(1). \quad (2.13)$$

2.5.3 Previsão utilizando HMM

Considere que queremos calcular a probabilidade de uma sequência de observação dada uma HMM $\lambda = (\pi, A, B)$. A sequência de observação de tamanho T é dada por $O = (o_1, o_2, \dots, o_T)$ e a sequência de estados escondidos $Q = (q_1, q_2, \dots, q_T)$.

A probabilidade de uma sequência de estados Q gerar uma sequência de observação O é dada por:

$$P(O|Q, \lambda) = b_{q_1 o_1} \times b_{q_2 o_2} \times \dots \times b_{q_T o_T}. \quad (2.14)$$

A probabilidade de transição pode ser calculada como

$$P(Q|\lambda) = \pi_{q_1} \times a_{q_1 q_2} \times a_{q_2 q_3} \times \dots \times a_{q_{T-1} q_T}. \quad (2.15)$$

A probabilidade conjunta é dada por:

$$P(O, Q|\lambda) = P(O|S, \lambda)P(Q|\lambda). \quad (2.16)$$

Portanto, a probabilidade da sequência de observação O ter sido gerada pela HMM definida por λ é:

$$P(O|\lambda) = \sum_S P(O|S, \lambda)P(Q|\lambda). \quad (2.17)$$

Com $S = \{q_1, q_2, \dots, q_T\}$ e realizando as substituições de $P(O|S, \lambda)$ (Equação 2.14) e $P(Q|\lambda)$ (Equação 2.15), temos:

$$P(O|\lambda) = \sum_{q_1 \dots q_T} \pi_{q_1} \prod_{t=1}^T a_{q_t q_{t+1}} b_{q_{t+1} o_t}. \quad (2.18)$$

2.5.4 Aprendizado utilizando HMM

Precisamos encontrar o conjunto de parâmetros $\lambda = (\pi, A, B)$ que melhor explica a sequência de observação O . Podemos definir este problema da seguinte forma:

$$\arg \max_{\lambda} P(O|\lambda). \quad (2.19)$$

Utilizaremos o algoritmo de Baum-Welch [88] para resolver este problema de forma iterativa. Esse algoritmo tem sido utilizado com sucesso para resolver este problema em diversos cenários de aplicação de HMM [23, 90]. O algoritmo faz uso conjunto dos algoritmos *forward* e *backward* buscando maximizar a probabilidade de observação. Para tanto, definimos a probabilidade de estar no estado i em um tempo t e no estado j em um tempo $t + 1$, dada uma HMM λ e uma sequência de observação O como:

$$p_t(i, j) = P(q_t = s_i, q_{t+1} = s_j | O, \lambda) = \frac{P(q_t = s_i, q_{t+1} = s_j, O, \lambda)}{P(O|\lambda)}. \quad (2.20)$$

Podemos definir também a probabilidade de estar no estado i em um tempo t , dada uma sequência de observação O e uma HMM λ como:

$$\gamma_i(t) = P(s_t = s_i | O, \lambda) \quad (2.21)$$

$$= \sum_{j=1}^N P(s_t = s_i, s_{t+1} = s_j | O, \lambda) \quad (2.22)$$

$$= \sum_{j=1}^N p_t(i, j) \quad (2.23)$$

Com base em uma estimativa inicial de λ podemos calcular as probabilidades $p_t(i, j)$ e $\gamma_i(t)$. Com base nesses valores podemos reestimar os parâmetros de uma HMM buscando

valores que melhor representam a sequência de observação O . A reestimativa pode ser realizada da seguinte maneira:

- π_i é a probabilidade de estar no estado s_i em um instante de tempo $t = 1$, ou seja,

$$\pi_i = \gamma_i(1). \quad (2.24)$$

- Uma estimativa para a_{ij} pode ser calculada dividindo o número esperado de transições do estado s_i para o estado s_j pelo número de transições em que a origem foi o estado s_i . Desta maneira, definimos:

$$a_{ij} = \frac{\sum_{t=1}^T p_t(i, j)}{\sum_{t=1}^T \gamma_i(t)}. \quad (2.25)$$

- Uma estimativa para b_{jk} pode ser calculada dividindo o número esperado de transições do estado s_i para o estado s_j que tiveram observação k pelo número de transições em que a origem foi o estado s_i . Dessa forma:

$$b_{jk} = \frac{\sum_{t: o_t=k, 1 \leq t \leq T} p_t(i, j)}{\sum_{t=1}^T \gamma_i(t)}. \quad (2.26)$$

Como vimos, o treinamento da HMM é feito através da execução do algoritmo de Baum-Welch iterativamente. A cada iteração, a reestimativa é calculada e a probabilidade $P(O|\lambda)$ é calculada. O algoritmo para quando a diferença entre a probabilidade de observação anterior e a probabilidade a nova probabilidade de observação é menor do que um limiar definido. A complexidade computacional associada a este processo é $O(N^2l)$, onde N é a quantidade de estados escondidos e l é o tamanho da sequência de observação.

2.6 Árvores de Decisão e Florestas Aleatórias

Dentre os mecanismos de aprendizado de máquina se destacam os modelos formados por comitês. Esses modelos são interessantes por, ao agregar diversos modelos individuais, conseguirem normalmente melhores resultados do que a aplicação dos modelos individualmente. O mecanismo de aprendizado de máquina conhecido como floresta aleatória combina a maior precisão obtida pela formação do comitê com a capacidade de dividir problemas complexos em problemas menores da árvore de decisão. Nesta seção, apresentaremos inicialmente a modelagem das árvores de decisão, detalhando seu o processo de aprendizagem e de previsão. Em seguida, apresentamos como um comitê é formado e como a previsão individual de cada modelo é agregada para formação da previsão final.

2.6.1 Árvores de Decisão

Uma árvore de decisão é uma estrutura baseada no processo de decisão sequencial, no qual as variáveis de entrada são particionadas em regiões. A partir do nó raiz de uma árvore uma característica de entrada é avaliada e um dos dois caminhos possíveis é selecionado (no caso de árvores binárias). Este processo é repetido até que uma folha seja encontrada. A folha representa a característica que é de interesse da previsão. O detalhamento apresentado nesta seção segue as definições de árvore de decisão apresentada por Bishop [91].

A Figura 2.5 apresenta um exemplo de particionamento das variáveis de entrada e a respectiva estrutura da árvore de decisão. O exemplo considera que o conjunto de entrada possui duas variáveis: x_1 e x_2 . A primeira divisão é realizada com base na variável x_1 , utilizando o limite θ_1 , resultando em duas subáreas (uma contendo as subáreas A e B , e outra contendo as subáreas C , D e E). Cada uma das subáreas resultantes será posteriormente subdividida em subáreas menores até a formação final. Para qualquer entrada $x = x_1, x_2$, podemos definir qual é a subárea a qual esta amostra pertence percorrendo a árvore a partir do nó raiz. Em cada nó intermediário, a entrada será avaliada de acordo com os critérios de particionamento até que uma folha seja encontrada. Ao encontrar uma folha, a variável de saída $y \in \{A, B, C, D, E\}$ assume o valor associado a folha selecionada.

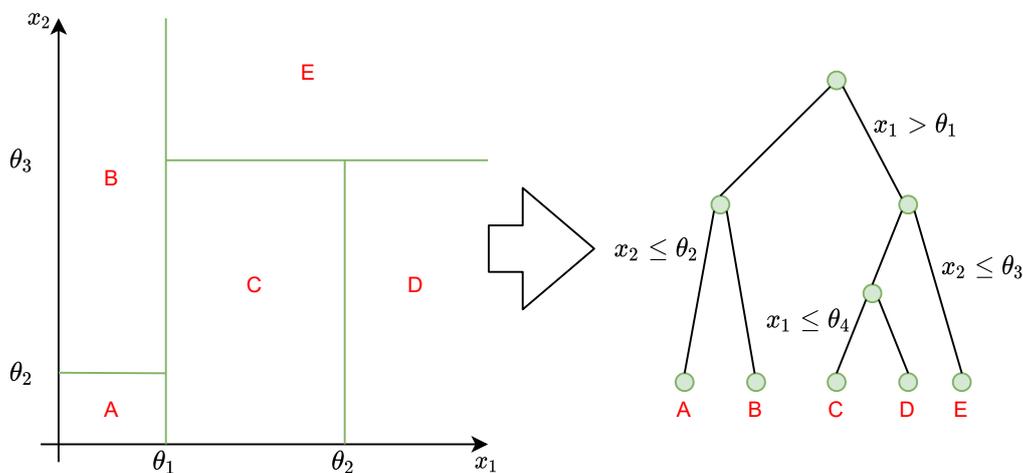


Figura 2.5: Exemplo da representação no plano cartesiano das subáreas e da estrutura da árvore de decisão, para um problema com duas variáveis de entrada.

A estrutura apresentada pode ser utilizada para problemas de regressão e para problemas de classificação. Em um problema de regressão, a variável y associada a cada uma das folhas da árvore assume um valor numérico constante. Em problemas de classificação a variável y associa cada uma das regiões (folhas) a uma classe específica. Portanto, para descrever a estrutura da árvore de decisão precisamos definir o conjunto de variáveis de

entrada x , o valor do limiar do critério de divisão e as variáveis avaliadas em cada nó e os valores que a variável de saída y assumirá naquela região.

A Figura 2.6 ilustra uma árvore de decisão que foi treinada com o conjunto de treinamento composto por N vetores de entrada $X = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_N\}$ e os respectivos mapeamentos para a variável de saída $Y = \{t_1, t_2, \dots, t_N\}$. Considerando inicialmente o problema de regressão no qual o objetivo é prever uma variável alvo $t \in \mathbb{R}$ a partir das variáveis de entrada $\bar{x} = \{x_1, x_2, \dots, x_D\}$, generalizando o problema para uma entrada com D variáveis. Considere também que as variáveis de entrada foram particionadas em τ . Se C_τ é o conjunto contendo todos os valores de saída do conjunto de treinamento de uma árvore de decisão que pertencem a área τ , podemos calcular a variável alvo t como a média dos valores do conjunto Y daquela subárea.

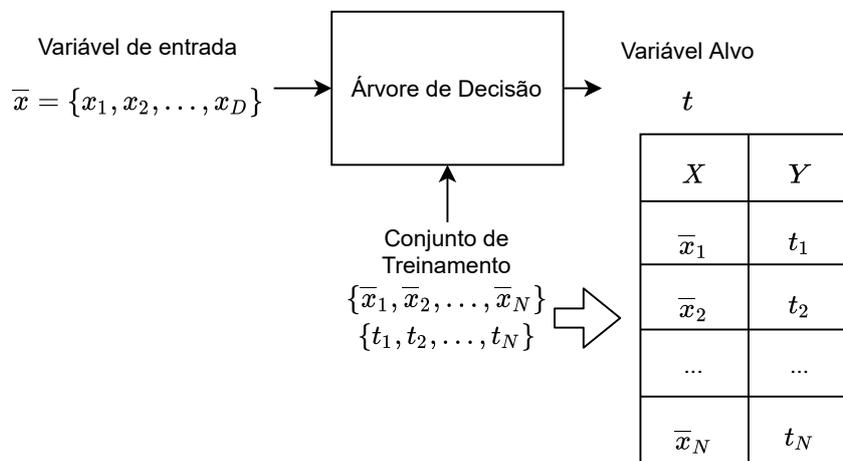


Figura 2.6: Variável de entrada, variável alvo e conjunto de treinamento para árvore de decisão.

Na avaliação que fizemos na Figura 2.6 assumimos que a estrutura da árvore de decisão já havia sido definida para mostrar o uso da árvore na avaliação da variável de entrada e da definição da variável alvo de saída. Para determinar a estrutura ótima da árvore de decisão, o erro quadrático médio é utilizado como medida de qualidade da árvore. Porém, a busca da estrutura da árvore que minimiza o erro quadrático médio entre o valor da variável alvo t e os valores do conjunto Y é computacionalmente impraticável. Uma abordagem de otimização conhecida como otimização gulosa (*Greedy Optimization*) pode ser utilizada no lugar da busca exaustiva para resolver esse problema. O procedimento é composto de duas fases: o crescimento da árvore e a poda da árvore. Na etapa de crescimento da árvore, inicia-se com uma árvore que é composta apenas pelo nó raiz. A cada passo, a divisão ocorrerá de forma a adicionar um par de folhas à estrutura da árvore, de modo a criar subáreas. Para completar a divisão é necessário escolher a subárea que será dividida, a variável de entrada (das D possíveis) e o limiar. Essa escolha é feita

testando todas as opções. Nas novas subáreas, o valor da variável alvo t é definido pela média aritmética dos valores do conjunto Y pertencentes aquela subárea. O conjunto que gerar o menor erro quadrático médio é escolhido como configuração da nova árvore. O processo de crescimento da árvore é executado até que um critério de parada seja satisfeito. Usualmente pode-se aplicar dois critérios de parada: parar de adicionar nós quando o erro quadrático médio estiver abaixo de um limiar especificado, ou quando o número de amostras associadas às folhas (subáreas) for atingido. A segunda etapa do procedimento é a poda, que leva em consideração uma combinação entre o erro quadrático médio e uma medida da complexidade do modelo gerado, de modo decidir quais subáreas serão combinadas para formar uma nova subárea.

Ao contrário dos problemas de regressão, nos quais $t \in \mathbb{R}$, para problemas de classificação a variável alvo t pode assumir valores inteiros no intervalo $1, 2, \dots, K$. Para classificação o processo de crescimento e poda da árvore é similar, tendo o erro quadrático médio substituído por uma medida de desempenho mais apropriada, como a Entropia Cruzada e o Índice Gini [91]. Durante o processo de crescimento da árvore, os dois valores incentivam a formação de subáreas em que grande parte das amostras são mapeadas em uma mesma classe. Na poda, o erro de classificação é normalmente aplicado.

Por ser baseada no processo de decisão sequencial, as árvores de decisão são de fácil interpretação por humanos. Isso as tornam versáteis para para subdividir problemas complexos nos quais diversos fatores atuam sobre a classificação ou regressão, mas que podem ser avaliados em decisões individuais mais simples de forma sequencial. Por outro lado, essa estrutura é muito sensível a variações no conjunto de treinamento, ou seja, uma pequena modificação no conjunto de treinamento pode gerar uma árvore muito diferente.

2.6.2 Agregação de Classificadores

Modelagem de Comitês (do inglês, *Ensemble Modeling*) é um processo no qual modelos individuais são empregados para produzir uma previsão ou saída [92]. A motivação para a utilização de modelos de comitês é reduzir o erro de previsão. Se os modelos são diversos e independentes, o erro de previsão pode ser reduzido quando a modelagem de comitês é utilizada. Esta modelagem realiza a agregação das previsões individuais de modo a produzir uma única previsão na saída.

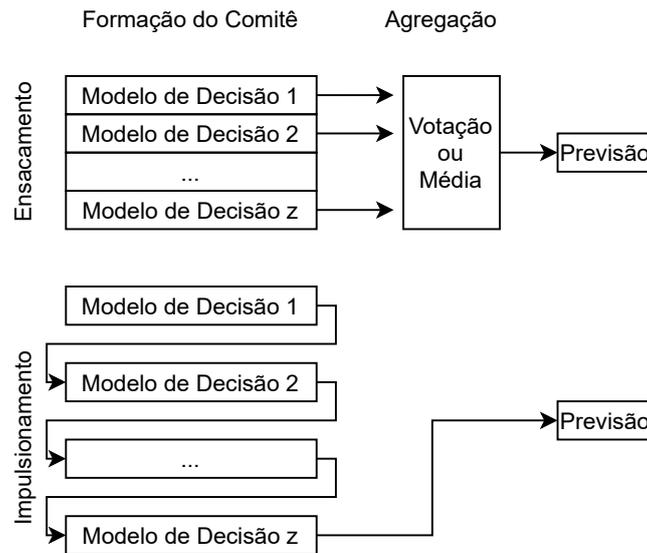


Figura 2.7: Estratégias de formação de comitês para agregação de modelos individuais de classificação e regressão.

Os dois métodos mais populares de formação de comitês são ensacamento (*bagging*) e impulsionamento (*boosting*) e estão ilustrados na Figura 2.7. No **ensacamento** diversos modelos individuais são treinados de forma paralela. Cada modelo individual é treinado com uma porção aleatória dos dados de treinamento. No **impulsionamento** diversos modelos individuais são treinados de forma sequencial. Cada modelo individual aprende a partir dos erros cometidos pelo modelo anterior.

Em um comitê com múltiplas estruturas de decisão, é preciso definir um método de agregação das decisões individuais. Existem três métodos que podem ser aplicados para agregação:

- **Votação:** a previsão final é feita por votação da maioria. Usualmente utilizada para problemas de classificação.
- **Média:** a previsão final é a média dos valores individuais de cada modelo de decisão. Comumente utilizada para problemas de regressão, mas pode ser aplicada também para problemas de classificação.
- **Média Ponderada:** a previsão final é a média ponderada dos valores individuais de cada modelo de decisão, onde cada modelo individual pode ter um peso diferente. Tradicionalmente utilizada para problemas de regressão.

Uma floresta aleatória é um modelo de comitê que emprega o método de ensacamento (*bagging*) e que os modelos individuais são árvores de decisão. Como vimos no fim da

Seção 2.6.1, as árvores de decisão são particularmente sensíveis à variação no conjunto de treinamento. Ao combinar diversos modelos, cada um treinado com uma porção selecionada aleatoriamente do conjunto de treinamento, a floresta aleatória é menos susceptível a variações no conjunto de treinamento que uma única árvore de decisão. A implementação usual das florestas aleatórias emprega, além do método de ensacamento, um método adicional para redução da complexidade de cada árvore. O método é conhecido como *subspace sampling* e consiste utilizar um subconjunto aleatório das N variáveis de entrada disponíveis em \bar{x} no treinamento de cada árvore de decisão que compõe a floresta aleatória. Com esse procedimento, a floresta aleatória resultante tende a ser mais variada em sua composição, com o benefício adicional da redução do tempo de treinamento.

A complexidade em tempo necessária para o treinamento de uma floresta aleatória é $O(vpN \log^2 N)$ [93], onde v é o número de árvores na floresta, N é o número de amostras de entrada no conjunto de treinamento X , $p \ll D$ é o número de variáveis selecionadas, dentre as D disponíveis, no método *subspace sampling*. Ressaltamos que o procedimento de otimização e validação cruzada detalhado na Seção 2.6.3 não foi considerado na complexidade apresentada. Portanto, a complexidade apresentada corresponde ao processo de treinamento em que os parâmetros da árvore de decisão foram fixados para treinamento. Também não contempla a execução da validação cruzada.

2.6.3 Otimização dos Parâmetros e Validação Cruzada

No treinamento de cada modelo de decisão que compõe o comitê em uma Floresta Aleatória podemos executar o algoritmo de otimização dos parâmetros de configuração disponível em cada modelo de decisão. No caso de árvores de decisão, os parâmetros são o número máximo de divisões, o tamanho máximo das folhas, o número de variáveis consideradas em cada nó de decisão e o critério de divisão de um nó. A escolha do valor ótimo para esses parâmetros é feita com base em uma métrica de avaliação do erro associado ao modelo de decisão. A Figura 2.8 mostra a utilização de validação cruzada associada ao erro de classificação para otimização das árvores de decisão que compõem a floresta aleatória.

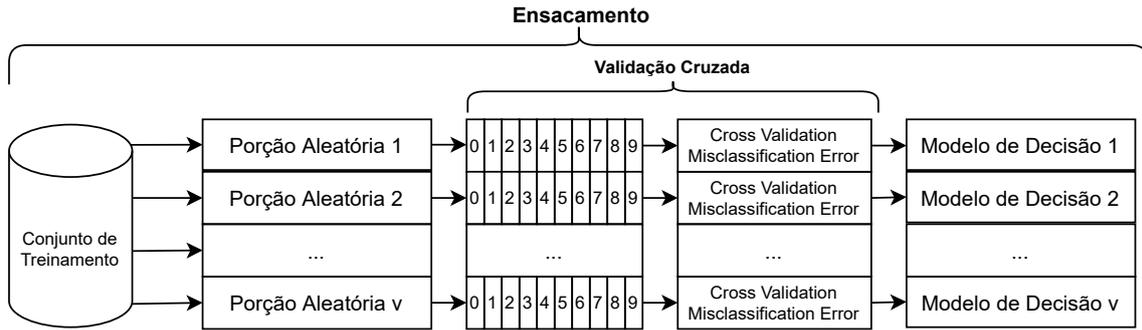


Figura 2.8: Utilização da validação cruzada no processo de treinamento de um comitê formado pelo processo de ensacamento.

A primeira fase do processo de ensacamento (*bagging*) é selecionar as amostras de treinamento para cada modelo de decisão que irá compor o comitê. Nesta fase, v porções selecionadas aleatoriamente do conjunto de treinamento são definidas. Cada porção é então dividida em k partes iguais, nas quais a árvore de decisão é treinada em $k - 1$ partes e testada na parte restante. Este processo é repetido k vezes de forma que todas as partes são utilizadas tanto para treinamento quanto para teste. Sendo e_k , a medida do erro de classificação em cada execução, podemos calcular erro de classificação E como a média dos erros individuais de cada execução, portanto:

$$E = \frac{\sum_{i=1}^k e_i}{k}. \quad (2.27)$$

A escolha dos parâmetros da árvore de decisão é feita com base no valor obtido de E . O conjunto de parâmetros que minimiza o valor de E é escolhido e a árvore de decisão é utilizada para compor o comitê. Este processo é executado em cada uma das v árvores de decisão que compõem o comitê.

2.7 Discussão

O compartilhamento de canais é a chave para termos um uso mais eficiente na utilização dos canais, já que permite que vários usuários compartilhem o canal sem que seja causada interferência prejudicial para os participantes. Os mecanismos de aprendizado de máquina têm sido aplicados com sucesso em várias áreas do conhecimento com resultados promissores no tratamento de complexos e, portanto, é plausível considerar sua aplicação para a realização de previsões de espectro. Por outro lado, a complexidade computacional do método utilizado pode inviabilizar, em diversos cenários, sua aplicação. Portanto, ao avaliar as opções de aplicação de aprendizado de máquina é importante considerar um

balanço entre o benefício obtido e o custo computacional necessário para execução. No próximo capítulo apresentaremos a revisão das principais técnicas aplicadas para previsão de espectro e suas principais características.

Capítulo 3

Revisão do Estado da Arte

Como vimos na Seção 2.4.2, realizar previsão do espectro auxilia o SU a executar o compartilhamento do canal de forma mais eficiente. O desafio para o SU é identificar corretamente as oportunidades de modo a viabilizar a utilização do canal para suas próprias transmissões. Para realizar a previsão do espectro, um SU emprega técnicas de sensoriamento de espectro para obter as características das transmissões do PU nos canais de interesse. Neste contexto, é comum que os SUs considerem que o PU transmite em canal dividido em *slots* de tempo, de modo que o resultado do sensoriamento seja uma descrição das características da atividade do PU no canal durante o intervalo de tempo delimitado pelo *slot* [23, 94, 16, 17, 18].

As características obtidas durante o monitoramento incluem o “estado de ocupação”, o “ciclo de ocupação” e o “nível de potência recebida” em cada um dos canais [16]. O “estado de ocupação” de cada *slot* pode ser determinado aplicando-se um método de detecção da presença de transmissões do PU [18]. Ao monitorar o “ciclo de ocupação” do canal, um SU coleta informações sobre a porção de tempo em que houve detecção da presença de transmissões do PU no canal durante um período predeterminado [94]. O “nível de potência recebida” refere-se a energia recebida durante um *slot* de tempo. A evolução temporal, espectral e espacial destas três características pode ser utilizada por algoritmos de previsão estatística e de aprendizado de máquina para estimar o comportamento futuro do PU [9]. Estas técnicas têm sido empregadas na tentativa de reconhecer o padrão das transmissões do PU, para identificar oportunidades de transmissão [16]. Ao identificar corretamente as oportunidades um SU pode realizar transmissões sem causar interferência prejudicial nas transmissões do PU.

As previsões realizadas podem indicar a ocupação de apenas um *slot* ou de um conjunto de *slots* no futuro [21]. No Capítulo 1 e no Capítulo 2 utilizamos os termos previsão de curta duração e previsão de longa duração para se referir às previsões de curto prazo e as previsões de longo prazo. Deste ponto em diante, adotaremos essas duas nomenclaturas

de forma intercalada para se referir a estas previsões. As previsões que indicam o estado de apenas um *slot* no futuro são chamadas de previsão de curto prazo [95, 96, 19, 97]. As previsões que indicam a ocupação de mais de um *slot* no futuro são chamadas de previsão de longo prazo [98, 20, 21, 23]. As previsões de longo prazo são especialmente desafiadoras por conta do problema de acumulação de erro [99]. Vários trabalhos utilizam a previsão de longo prazo para determinar a ocupação de um número fixo de *slots* à frente [98, 20, 21, 100, 101]. Nesses trabalhos o problema de acumulação de erro está associado às previsões para os *slots* à frente do *slot* seguinte. Ao realizar previsões para esses *slots*, os preditores levam em consideração apenas estimativa obtida para os *slots* anteriores e não o estado de ocupação que o *slot* estará de fato, que só será determinado no futuro com a realização do sensoriamento naquele *slot*. Este capítulo apresenta a revisão do estado da arte das principais técnicas empregadas para previsão de espectro.

3.1 Seleção dos Trabalhos Relacionados

Nesta seção definiremos uma metodologia de pesquisa aplicada às bases de publicação, de forma que os artigos selecionados sejam representativos para a área de pesquisa que investiga mecanismos de previsão de espectro. O interesse desta pesquisa será voltado para mecanismos de previsão de espectro visando facilitar ou subsidiar a coexistência entre PU e SU em canais com uso compartilhado, nos quais a arquitetura de rede é distribuída (conforme definições apresentadas na Seção 2.2.1) e o método de acesso segue o modelo hierárquico (conforme apresentado na Seção 2.2.3). Técnicas de aprendizado de máquina se mostram promissoras para lidar com as complexas dependências existentes na caracterização do canal realizada pelo SU. Contudo, o emprego de aprendizado de máquina ainda é um desafio para nós de rede com restrições de poder computacional para execução de maneira distribuída. Felizmente nos últimos anos o poder computacional e a autonomia de energia nos nós de rede tem crescido consideravelmente, viabilizando a aplicação de aprendizado de máquina para previsão de espectro.

Para esta revisão literária, as seguintes diretrizes guiaram nossas buscas. O horizonte temporal de 5 anos foi definido como critério de inclusão dos artigos neste estudo. Como esta não é uma área de pesquisa recente, muitos trabalhos fundamentais foram publicados fora do limite de tempo definido. Os trabalhos que julgamos importantes fora da delimitação foram destacados e detalhados no Capítulo 2 deste trabalho. Portanto, o objetivo desta revisão do estado da arte é mostrar os avanços recentes relacionados a previsão de espectro. Como uma das bases que utilizamos não nos permite refinamento da busca por mês de publicação, decidimos incluir os artigos publicados de 2017 em diante. Na busca textual, filtramos os trabalhos que tenham as palavras *spectrum* e *prediction* ou *spectrum*

e *inference* no campo Resumo (*Abstract*). Como estes termos são também utilizados para alguns trabalhos na área médica, buscamos pelos trabalhos que continham no campo Texto Completo (*Full Text*) os termos *spectrum*, *prediction* e *occupancy*. Como forma de buscar os trabalhos com maior relevância na área de pesquisa atualmente, restringimos a revisão apenas para artigos publicados em conferências que estão indexadas no Qualis 2021 [102]. Os critérios de inclusão dos artigos na lista de revisão estão consolidados na Tabela 3.1.

Tabela 3.1: Critérios de inclusão de artigos e trabalhos na revisão.

Critério	Regra	Conteúdo
Resumo (<i>Abstract</i>)	Contém	“ <i>Spectrum Prediction</i> ” ou “ <i>Spectrum Inference</i> ”
Texto Completo (<i>Full Text</i>)	Contém	<i>Spectrum e Prediction e Occupancy</i>
Ano de publicação	No intervalo	2017 - 2021
Qualis 2021	Possui	Classificação A ou B

Os artigos selecionados utilizando os critérios estabelecidos estão apresentados na Tabela 3.2, junto com o ano de publicação e sua classificação no Qualis 2021 [102]. Ao realizar a previsão um SU está interessado em explorar padrões de uso identificados nos dados históricos do canal monitorado. O foco do SU é identificar características futuras como (i) estado do canal, isto é, prever o estado do canal como ocupado ou desocupado, (ii) ciclo de ocupação, isto é, previsão da porção de tempo em que o canal está ocupado, (iii) nível de potência recebida, isto é, previsão do nível de potência recebida em um canal específico para determinar sua qualidade [16]. A característica para a qual a previsão é realizada em cada um dos trabalhos está indicada na coluna “Característica de Interesse” na Tabela 3.2.

Tabela 3.2: Comparativo das características dos trabalhos da área.

Artigo	Autores	Ano de Publicação	Qualis 2021	Característica de Interesse
1	Baddour <i>et al.</i> [103]	2018	A1	Ciclo de Ocupação
2	Saad <i>et al.</i> [23]	2019	A1	Estado do Canal
3	Zhao <i>et al.</i> [96]	2019	A4	Estado do Canal
4	Li <i>et al.</i> [19]	2019	B2	Estado do Canal
5	Shawel <i>et al.</i> [16]	2019	A3	Nível de Potência Recebida
6	Zuo <i>et al.</i> [95]	2020	A1	Estado do Canal
7	Ren <i>et al.</i> [17]	2020	A1	Nível de Potência Recebida
8	Yang <i>et al.</i> [104]	2020	A4	Estado do Canal
9	Aygul <i>et al.</i> [97]	2020	A1	Estado do Canal
10	Kyeremateng-Boateng <i>et al.</i> [105]	2020	A3	Estado do Canal
11	Bezerra <i>et al.</i> [106]	2020	A3	Estado do Canal
12	Al-Tahmeesschi <i>et al.</i> [94]	2020	A3	Ciclo de Ocupação
13	Liu <i>et al.</i> [107]	2021	A3	Nível de Potência Recebida
14	Yang <i>et al.</i> [18]	2021	A4	Estado do Canal

Nas seções seguintes iremos apresentar o detalhamento dos artigos listados na Tabela 3.2, considerando a classificação indicada na coluna “Característica de Interesse”. Apresentaremos inicialmente os artigos que contemplam a previsão do estado do canal, detalhando o formato comum de caracterização que os trabalhos apresentam na modelagem dos preditores. Em seguida apresentaremos os artigos cujo objetivo é realizar a previsão do ciclo de ocupação e as motivações que levaram os autores a propor este formato de previsão. Por fim, apresentaremos os artigos que buscam preditores para estimar o nível de potência recebida e os benefícios obtidos ao adotar esta representação.

3.1.1 Previsão do Estado do Canal

Nesta seção nos dedicaremos a apresentar os trabalhos cuja característica de interesse foi classificada como “Estado do Canal” na Tabela 3.2. Como vimos na Seção 2.3.1, a ocupação de um canal pode ser determinada a partir da informação de potência recebida utilizando um detector por energia. Deste modo, ao comparar a potência recebida em cada canal com um limiar, podemos determinar se o canal está ocupado ou desocupado. Quando a potência recebida estiver abaixo do limiar o canal é indicado como desocupado, senão, o canal é tido como ocupado. A representação comum na literatura utiliza 0 para indicar um *slot* desocupado e 1 para indicar um *slot* ocupado. A Tabela 3.3 lista os trabalhos cujo objetivo é realizar previsão da ocupação do canal, indicando a quantidade de canais no cenário avaliado, se a previsão é referente apenas a um *slot* a frente ou a múltiplos *slots* a frente e a característica do PU presente no canal. Mantivemos a numeração da tabela de origem (Tabela 3.2) para facilitar a correlação entre as classificações. O detalhamento dos trabalhos que faremos a seguir adará a ordem descrita a seguir.

Inicialmente iremos apresentar os trabalhos que tratam do cenário com um único canal e realizam previsões para um *slot* a frente. Em seguida, serão apresentados os trabalhos que tratam do cenário com múltiplos canais e que as previsões são referentes a apenas um *slot* a frente. Por fim, apresentaremos os trabalhos que tratam de previsão para múltiplos *slots* a frente.

Tabela 3.3: Classificação dos artigos cujo objetivo é realizar previsão da ocupação dos canais.

Artigo	Autor	Quantidade de Canais	Número de <i>slots</i> na Previsão	Carac. do Tráfego
2	Saad <i>et al.</i> [23]	Um canal	Múltiplos <i>slots</i> a frente	Coletas Reais
3	Zhao <i>et al.</i> [96]	Um canal	Um <i>slot</i> a frente	Tráfego Sintético e Real
4	Li <i>et al.</i> [19]	Múltiplos canais	Um <i>slot</i> a frente	Coletas Reais
6	Zuo <i>et al.</i> [95]	Um canal	Um <i>slot</i> a frente	Coletas Reais
9	Aygul <i>et al.</i> [97]	Múltiplos canais	Um <i>slot</i> a frente	Coletas Reais
10	Kyeremateng-Boateng <i>et al.</i> [105]	Um canal	Um <i>slot</i> a frente	Tráfego Sintético
11	Bezerra <i>et al.</i> [106]	Um canal	Múltiplos <i>slots</i> a frente	Tráfego Sintético
14	Yang <i>et al.</i> [18]	Um canal	Um <i>slot</i> a frente	Coletas Reais

Zuo *et al.* [95] avalia o desempenho do preditor baseado em uma combinação de MLP (*MultiLayer Perceptron* - MLP) e Aprendizado por Reforço. Utilizando 2.400 grupos de amostras obtidas de um único canal Wi-Fi monitorado por 50 segundos, o método proposto obteve 89,01% de acerto nas previsões realizadas em contraponto com 78,27% obtidos pela previsão utilizando HMMs. O método proposto é capaz de fazer uso de estatísticas das coletas como a taxa de ocupação, auto-similaridade e entropia para melhorar o desempenho das previsões realizadas. Uma evolução deste trabalho foi apresentada por Yang *et al.* [18], no qual o MLP é substituído por DRL (*Deep Reinforcement Learning* - DRL) em conjunto com um classificador resultando no aumento da taxa de acerto para 90,01%. Os trabalhos de Zuo *et al.* [95] e Yang *et al.* [18] consideram que o monitoramento do canal é realizado a partir de um ponto fixo, assumindo que os SUs não possuem habilidade de se movimentar. Zhao *et al.* [96] propõe a utilização de um preditor baseado em HMM no qual a matriz de transição varia de acordo com a localização, para aplicações de comunicação com veículos aéreos não tripulados. O estudo discute dois cenários com o comportamento do PU gerado de forma sintética a partir de distribuições de Poisson e Uniforme. O preditor proposto obteve 72,12% de previsões corretas no cenário com distribuição de Poisson e 66,54% no cenário com distribuição Uniforme.

Os trabalhos apresentados até o momento consideram realizar previsão para apenas um *slot* a frente com interesse no cenário em que um único canal é monitorado. Aygul *et al.* [97] adotam uma representação da ocupação diferente, de forma que a representação indique o estado de ocupação de diversos canais. Este trabalho realiza previsão para um conjunto de 3.000 canais monitorados por uma hora, com amostras a cada segundo. A previsão indica o provável estado de todos os canais no próximo *slot*. O preditor foi

elaborado utilizando LSTM (*Long Short-Term Memory* - LSTM) e obteve em torno de 33% de colisão com o PU. Li *et al.* [19] também sugerem um preditor com LSTM para previsão em diversos canais, e obteve precisão em torno de 70%. O preditor foi avaliado em um conjunto de coletas contendo 6.770 amostras de 70 canais. O intervalo entre amostras foi configurado para 3 minutos. Yang *et al.* [104] avaliam a previsão da ocupação diária de diversos canais utilizados como *downlink* do satélite LEO. As amostras diárias dos canais monitorados definem a quantidade de canais considerados ocupados naquele dia, ou seja, nenhuma evolução temporal do canal durante o dia é considerada. Para realizar a previsão, fazem uso de regressão linear com o objetivo de obter uma estimativa para a porcentagem de canais que estarão ocupados dentro da banda observada. Este trabalho sofre com a falta de padronização dos dados obtidos diariamente, sendo que o período de observação não é uniforme entre os diferentes dias de monitoramento.

As previsões de curto prazo não são influenciadas pelo problema de acumulação de erro, pois as previsões fazem referência apenas ao *slot* imediatamente seguinte. Ao realizar a previsão de apenas um *slot* no futuro, os SUs ficam limitados a explorar individualmente cada *slot* previsto como desocupado. Nas previsões de longo prazo, o problema de acumulação de erro se torna latente quando a previsão para um determinado *slot* no futuro depende de outro *slot* que não teve seu estado de ocupação determinado, existindo apenas uma estimativa. Previsão de longo prazo pode ser encontrada em [98, 20, 21, 100, 101] para um número fixo de *slots* à frente. Ao realizar previsões que identifiquem o estado de ocupação de múltiplos *slots* à frente, o SU pode explorá-los de forma conjunta, de modo a maximizar a capacidade de transmissão de dados durante o período em que o canal permanecerá desocupado. Com esta motivação, Saad *et al.* [23] sugerem uma abordagem de caracterização que permite adequar o procedimento de previsão, de modo que o preditor consiga indicar a duração do período ocioso. Essa abordagem permitiu a utilização do preditor baseado em HMM para previsão de múltiplos *slots* a frente sem ser afetado pelo problema de acumulação de erro. A partir da caracterização tradicional em que cada *slot* é caracterizado como ocupado ou desocupado empregando-se uma representação binária, os autores sugerem um novo formato de caracterização da observação do canal. Neste novo formato, uma sequência de *slots* com mesma classificação é representada por um símbolo que indica o número de *slots* em sequência e o estado de ocupação do canal. Neste formato, os autores puderam elaborar um preditor baseado em HMM que é capaz de estimar a duração do período em que o canal estará desocupado.

A seguir apresentaremos os trabalhos nos quais a característica de interesse da previsão é o Ciclo de Ocupação (do inglês, *Duty Cycle* - DC).

3.1.2 Previsão do Ciclo de Ocupação

Como vimos na Seção 3.1.1, os trabalhos apresentados buscam realizar previsão do estado de ocupação do canal empregando diversas técnicas. Os trabalhos apresentados modelam o monitoramento dos canais de interesse em um formato em que podem determinar diretamente a ocupação de cada um dos canais. A partir destas informações podem indicar, também diretamente, a previsão de ocupação no futuro de cada um dos canais. Nestes trabalhos a previsão indica se os *slots* seguintes estariam ocupados ou desocupados. Nos trabalhos que apresentaremos nesta seção o foco é prever o Ciclo de Ocupação (do inglês, *Duty Cycle* - DC). O DC pode ser definido como a fração de tempo no qual o um canal permaneceu ocupado dentro de um ciclo predefinido [103]. A escolha da duração de cada ciclo é feita de modo a agregar a indicação de ocupação individual de cada *slot* no intervalo de tempo em um único valor. Neste formato, o DC pode ser utilizado como um indicativo da taxa de ocupação do canal, servindo de insumo para uma abordagem de alocação de canais baseadas no nível de ocupação dos canais [103].

Baddour *et al.* [103] define que cada ciclo possui duração de 1 hora. A cada hora o valor da ocupação é calculado por meio das amostras coletadas no período. Ao todo 5.294 canais são monitorados, porém os canais com ocupação média menor do que 10% e maior do que 90% não são considerados. Vários métodos de regressão, como ARIMA (*Autoregressive Integrated Moving Average* - ARIMA), ETS (*Extended Exponential Smoothing* - ETS) e XGBoost (*Extreme Gradient Boosting* - XGBoost), entre outros, são utilizados para realizar previsão do ciclo de ocupação para 34 horas a frente, baseado no histórico de aproximadamente 4 semanas. O Erro Percentual Absoluto Médio (do inglês, *Mean Absolute Percentage Error* - MAPE) [108] é calculado para cada método de regressão. Para cada canal, o método de regressão com menor MAPE é selecionado para previsão. Os autores também propõem o uso de um classificador baseado em Floresta Aleatória de modo a indicar o método de regressão a ser utilizado em cada canal. A tarefa do classificador é escolher, com base no histórico de cada canal, a entre as classes disponíveis (cada classe representa um método de regressão). O classificador foi capaz de escolher o método de regressão com o menor MAPE em aproximadamente 50% dos casos avaliados.

Diferente do trabalho anterior, que avaliou um cenário com diversos canais, o trabalho publicado por Al-Tahmeesschi *et al.* [94] apresenta os resultados de previsão do DC para apenas um canal. Nesse trabalho os autores utilizam dados de monitoramento do canal 6 de uma rede WiFi considerando que cada ciclo de ocupação dura 100ms. Amostras de 4 dias são obtidas e armazenadas para análise. Cada amostra representa a fração de tempo em que o canal observado estava ocupado durante o período de observação. Os autores propõem o uso de DNN (*Deep Neural Networks* - DNN) para estimar o valor do DC no próximo ciclo. No método proposto o ciclo de ocupação é previsto com um alto grau de

precisão.

Previsão do ciclo de ocupação pode ser encontrado na literatura em outros trabalhos como o de Toma *et al.* [109], Al-Tahmeesschi *et al.* [110] e Sikiru *et al.* [111], dentre outros. Esses não foram incluídos nesta revisão por não atenderem pelo menos uma das restrições definidas na Tabela 3.2. Na seção seguinte iremos apresentar os trabalhos cujo objetivo é realizar a previsão do nível de potência recebida.

3.1.3 Previsão do Nível de Potência Recebida

Os trabalhos apresentados na Seção 3.1.1 e na Seção 3.1.2 dependem da correta identificação das atividades do PU nos canais monitorados. A representação binária da ocupação do canal utilizada nesses trabalhos pode não permitir a avaliação de parâmetros de qualidade como nível de interferência das transmissões do PU. Especialmente quando o objetivo é identificar padrões que incluem informação de posicionamento, a representação binária pode também não ser suficiente. Ren *et al.* [17] argumentam que ao utilizar o nível de potência recebida é possível inferir a localização de um transmissor e obter o alcance da interferência causada por sua transmissão. Com estas informações, segundo os autores, é possível indicar o estado de ocupação do canal e determinar nível de interferência na área de interesse. Na pesquisa realizada os trabalhos de Shawel *et al.* [16], Ren *et al.* [17] e Liu *et al.* [107] tratam de previsão em termos de potência recebida.

Liu *et al.* [107] avaliam um preditor baseado em uma combinação de clusterização e LSTM para previsão de potência recebida. Neste trabalho, a potência média é calculada em um intervalo de 1 minuto, com amostras sendo coletadas a cada 1 segundo. O conjunto de dados possui 10.000 minutos de coletas, dos quais 3.500 são utilizados para teste e o restante dos dados para treinamento do preditor. Os autores avaliam o desempenho de 6 diferentes preditores e mostram que a estratégia de clusterização consegue diminuir o Erro Quadrático Médio (do inglês, *Root Mean Squared Error* - RMSE) [108] e o MAPE se comparados à aplicação somente da LSTM. Os autores também avaliam os métodos de regressão ARIMA e RF, mas os resultados obtidos mostram que o RMSE e o MAPE são maiores quando esses métodos são empregados.

Ao contrário de Liu *et al.* [107] que avaliam apenas a evolução temporal da potência recebida, o trabalho publicado por Ren *et al.* [17] estuda a previsão utilizando CNN (*convolutional neural network* - CNN) para estimativa do valor da potência recebida na tentativa de capturar a correlação da evolução temporal e espacial. Os valores de potência são coletados continuamente por um conjunto de 100 sensores dispostos uniformemente em uma área de 20km por 20km. Os valores de potência recebida em cada sensor são representados por uma matriz com 10 linhas e 10 colunas. Dois cenários são avaliados, um contendo 23 transmissores e outro contendo 27 transmissores que se movem continuamente

em direções aleatórias dentro da área delimitada. Em cada cenário, estão disponíveis 6.000 matrizes com os valores de potência dos 100 sensores, coletadas a cada 150ms. 80% das amostras são utilizadas para treinamento e o restante para teste. Avaliando o MAPE e o RMSE, os autores concluem que a previsão realizada consegue alcançar valores muito próximos dos valores observados.

Uma proposta de utilização de LSTM para a estimativa de potência recebida considerando as dependências existentes no domínio do tempo, espaço e frequência foi proposta por Shawel *et al.* [16]. O cenário de avaliação consiste em 350 canais, 1600 localidades monitoradas por 5 dias com amostras de potência coletadas a cada 3 minutos. 80% das amostras são utilizadas para treinamento, 10% para validação e os 10% restantes para teste. O preditor elaborado avalia 6 horas do histórico de potência de todos os canais/localidades para estimar os valores de potência para os próximos 150 minutos. Os resultados indicam que o preditor possui comportamento estável na maioria dos canais avaliados, obtendo valores de RMSE em torno de 5 para a maior parte dos canais.

Como vimos, ao avaliar a evolução do comportamento da potência recebida os SUs podem estimar informações como a provável localização e a área de interferência causada pelas transmissões do PU. Na próxima seção discutiremos os principais aspectos relacionados à previsão de espectro.

3.2 Discussão

Neste Capítulo apresentamos um panorama das técnicas aplicadas para previsão de espectro e as características dos trabalhos relacionados. Ao realizar previsão de espectro um SU pode fazer uso das oportunidades identificadas sem causar interferência prejudicial ao PU. Diversas técnicas de aprendizado de máquina tem sido aplicadas na tentativa de identificar adequadamente oportunidades como HMM, LSTM, DRL e MLP, dentre outras.

Como indicado por Elias *et al.* [21], previsões de longo prazo são mais desafiadoras do que previsões de curto prazo, por conta do problema de acumulação de erro. Este problema afeta as propostas de previsão para um número fixo de *slots* a frente como as encontradas em [98, 20, 21, 100, 101]. A metodologia proposta por Saad *et al.* [23] permitiu a utilização de HMMs para realização de previsão de longo prazo, sem que as previsões fossem comprometidas pelo problema de acumulação de erro. Os autores avaliaram a utilização dos preditores em um cenário específico, no qual o comportamento do PU era definido por uma rede sem fio veicular. A aplicação de HMMs para previsão de espectro, nesse contexto, é atrativa por conta do seu baixo custo computacional de treinamento das HMMs, se comparados com outros métodos mais complexos de aprendizado de máquina.

Como discutimos na Seção 2.4.2, muitos mecanismos de aprendizado de máquina são sensíveis a efeitos de aprendizado como o sobre-ajuste (*overfitting*) e os pontos fora da curva (*outliers*), e podem resultar em modelos altamente especializados.

Como o preditor baseado em HMM para previsões de longo prazo sugeridas por Saad *et al.* [23] foi avaliado em um cenário específico, não é possível concluir, a partir do trabalho publicado, se o preditor é capaz de se adequar a outros comportamentos do PU. Os autores também não discutem a aplicação de outras técnicas de aprendizado de máquina mais complexas. Por isso, não é possível concluir se o preditor baseado em HMM, que possui custo computacional menor, obtém resultados semelhantes às técnicas mais elaboradas de aprendizado de máquina. Com essa motivação, a proposta deste trabalho é avaliar o uso do preditor baseado em HMM proposto por Saad *et al.* [23] em diferentes cenários de comportamento do PU. No Capítulo 4, apresentaremos o preditor baseado em HMM utilizado no escopo deste trabalho. Neste mesmo capítulo apresentamos duas propostas de aprimoramento para o preditor baseado em HMM e um preditor baseado em RF. A motivação para uso do RF está no fato de que esse modelo é menos susceptível aos efeitos de aprendizado anteriormente relatados. Os preditores serão avaliados em um cenário em que o comportamento do PU foi gerado de forma sintética, com base na distribuição de Poisson no Capítulo 5. No Capítulo 6, avaliaremos os preditores em uma base de coletas reais.

Capítulo 4

Proposta de Previsão de Ocupação do Espectro

A caracterização do comportamento do PU é fundamental para que se alcance a coexistência entre o PU e o SU. Como vimos no Capítulo 3, diversos métodos de previsão estatística e de aprendizado de máquina têm sido aplicados na tentativa de prever o comportamento do PU. Quanto maior a precisão da previsão, menor será o nível de interferência que o SU causará nas comunicações do PU. Porém, a escolha do conjunto de treinamento se mostra crucial no processo de aprendizagem de alguns métodos, com influência direta na capacidade do modelo treinado de realizar boas previsões. Neste sentido, é possível que o desempenho de métodos de aprendizagem sejam dependentes do comportamento do PU ou do seu padrão de transmissões no canal. Por este motivo, estratégias que modelam o comportamento do PU têm sido estudadas e testadas em diversos cenários, com o objetivo de alcançar o compartilhamento do canal com o mínimo impacto para as transmissões do PU. Neste capítulo apresentamos dois preditores distintos baseados em técnicas de aprendizado de máquina. Apresentaremos também o conjunto de métricas que serão utilizadas nos capítulos seguintes na avaliação destes preditores. Para finalizar, apresentaremos uma proposta de avaliação que permite combinar as métricas apresentadas em uma metodologia de escolha do melhor preditor para cada cenário.

4.1 Previsão de Ocupação do Espectro com HMM

Esta seção descreve o procedimento de previsão baseado em HMM proposto por Saad *et al.* [23]. Os procedimentos apresentados nesta seção são baseados na descrição do procedimento de previsão disponível em [23]. Inicialmente apresentaremos a composição do preditor e uma visão geral, de modo a evidenciar as características de cada componente do preditor. Mostraremos como a transformação proposta permite que o preditor indi-

que, não apenas a ocupação de um único *slot* no futuro, mas a duração em que o canal permanecerá desocupado.

4.1.1 Composição do Preditor

Os componentes do preditor são apresentados na Figura 4.1, no formato de diagrama de blocos. Aproveitamos o diagrama para explicitar o escopo deste trabalho. O bloco Sensoriamento do Espectro monitora os canais de interesse e obtém informações deles, tradicionalmente armazenadas como um vetor de quadratura em banda base. Neste mesmo bloco o sinal em quadratura é transformado em informações de potência e posteriormente em indicações de ocupação dos canais. De fato, a saída deste bloco identifica a ocupação dos canais monitorados e sua evolução com o tempo. O bloco Extração de Tamanhos é responsável por transformar a sequência gerada pelo bloco anterior, para que esta possa representar o estado de ocupação do canal e sua duração. Neste formato, os dados podem ser corretamente identificados pelo preditor para treinamento e realização de previsões. A partir deste ponto temos dois caminhos para os dados de observação. A primeira porção é destinada ao treinamento das HMM que compõem o preditor. Com os preditores treinados, as informações do canal são direcionadas a um módulo de memória, no qual os dados são armazenados como insumos para a realização da previsão. Com os insumos do bloco Treinamento e Memória, o bloco Previsão pode estimar o estado de ocupação futura do canal e a duração em que permanecerá neste estado. Um SU de posse desta estimativa poderá guiar o acesso oportunista ao canal para suas próprias comunicações. As estratégias necessárias de coordenação entre os SUs para evitar colisão estarão fora do escopo deste trabalho.

4.1.2 Sensoriamento do Espectro

A obtenção de informações dos sinais de rádio frequência são realizadas através de equipamentos especializados para esta função. Para as avaliações e propostas deste trabalho assumimos que o canal é dividido em *slots* de tempo, de forma semelhante ao adotado em diversos trabalhos [23, 94, 16, 17, 18]. Os sinais são coletados de forma periódica, de modo que as informações obtidas caracterizem a atividade do PU no canal em um *slot* de tempo de duração fixa. Os sinais são armazenados como um vetor de quadratura do sinal em banda base, de onde são extraídas as informações de potência do sinal e informações de ocupação do canal. O módulo de sensoriamento do espectro obtém informações do canal e produz uma saída binária $B \in \{0, 1\}$, que representa o estado de ocupação de um *slot* do canal monitorado. Para definir a ocupação do canal o SU pode utilizar qualquer uma das técnicas descritas na Seção 2.3, onde descrevemos o modelo de detector utilizado. Para

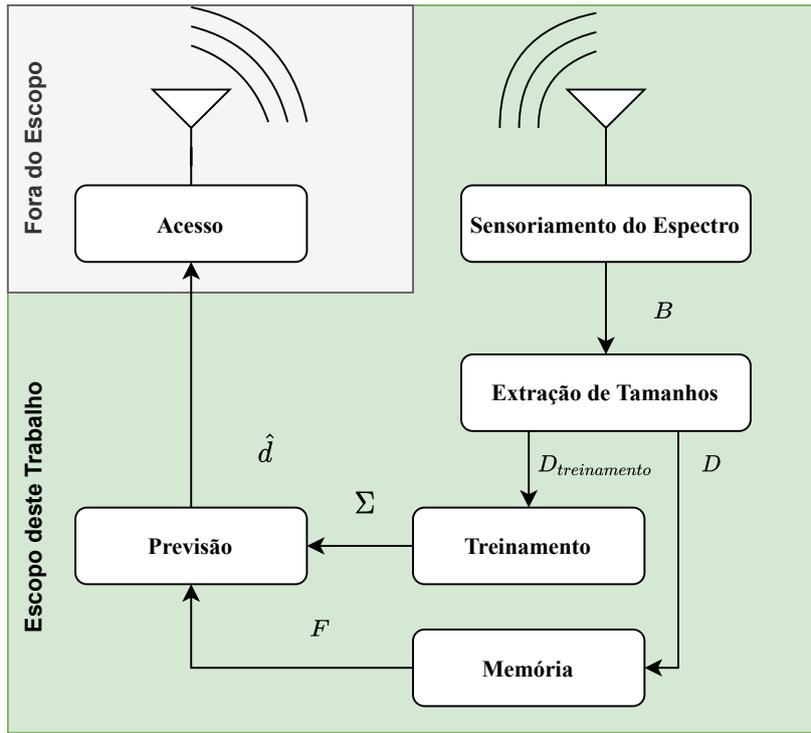


Figura 4.1: Modelo do sistema de previsão.

elaboração deste trabalho, assumimos que a sequência de entrada B reflete a ocupação do canal independente de qual técnica de sensoriamento utilizada. No uso comum desta representação 0 representa que o canal está livre (desocupado) e 1 que o canal está em uso (ocupado). Dado que o SU não possui conhecimento prévio do padrão de tráfego do PU, esta informação é considerada escondida para modelagem das HMMs.

4.1.3 Extração de Tamanhos

A transformação descrita nesta seção é essencial para que o preditor esteja apto a realizar a previsão que indique a duração em que o canal estará desocupado (previsão de longo prazo). A partir das informações do bloco Sensoriamento do Espectro o módulo de Extração de Tamanhos avalia a sequência binária B e extrai a duração dos estados ocupados e desocupados, formando a sequência $D = \{d_1, d_2, \dots, d_k\}$, onde k é a quantidade de elementos na sequência D . Este procedimento é baseado na transformação encontrada em [23, 112]. A sequência resultante desta transformação agrega a informação de *slots* consecutivos que tiveram a mesma indicação de presença do PU, ou seja, a sequência D evidencia o tempo em que o canal permaneceu em cada estado (ocupado ou desocupado). Para completar a representação, utilizamos símbolos diferentes para representar os dois

estados possíveis do canal observado: \mathcal{I} para o canal desocupado e \mathcal{B} para o canal ocupado. Conforme indicado no exemplo da Figura 4.2, o canal permanece 5 *slots* no estado ocupado e em seguida são observados 7 *slots* desocupados. Seguindo a representação sugerida, os elementos da sequência D para representar esses dois períodos são \mathcal{B}_5 e \mathcal{I}_7 .

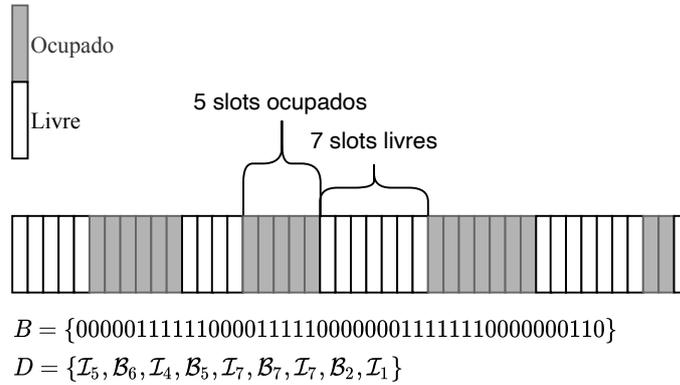


Figura 4.2: Exemplo da atuação do extrator de tamanhos nas sequências B e D .

A transformação executada neste bloco pode não ser necessária, dependendo do formato da caracterização do canal que está sendo estudada. É o caso, por exemplo, do tráfego sintético que será avaliado no Capítulo 5, no qual os dados são gerados diretamente no formato da sequência D . Por outro lado, no Capítulo 6, avaliaremos a base DySPAN, que necessitará da transformação descrita.

4.1.4 Treinamento

O bloco de treinamento é o responsável por ajustar as configurações do preditor com base no conjunto de treinamento disponível. Inicialmente todos os dados coletados são direcionados para o módulo de Treinamento. O módulo de Treinamento, após ter recebido uma quantidade representativa de dados de ocupação ($D_{treinamento}$), executa o algoritmo de treinamento para todas as HMMs presentes no preditor. A Figura 4.3 ilustra o processo adotado para treinamento do preditor e para a definição da sua composição a partir da sequência de treinamento. A ideia geral é de que a HMM treinada precisa identificar o comportamento do PU no canal monitorado para determinar o comportamento que o PU terá no futuro. Portanto, assumimos que exista uma dependência entre o que foi observado até o momento e o que será observado no futuro no canal. Cada HMM do preditor é responsável por identificar uma duração em que o canal estará desocupado, medido em número de *slots*. Para cada elemento \mathcal{I} na sequência de treinamento uma

HMM é treinada para reconhecer aquela duração do canal desocupado. Assim, no preditor existirá uma HMM para cada número inteiro entre 1 e I_{max} , sendo I_{max} o maior número de *slots* desocupados consecutivos observado. Como em uma sequência de treinamento pode não ocorrer todos os valores inteiros entre 1 e I_{max} , as durações que não ocorrerem terão suas respectivas HMMs removidas do preditor. Sendo I_{vazio} o número de durações que não ocorreram na sequência de treinamento, o número de HMMs no preditor pode ser definida como $\tau = I_{max} - I_{vazio}$.

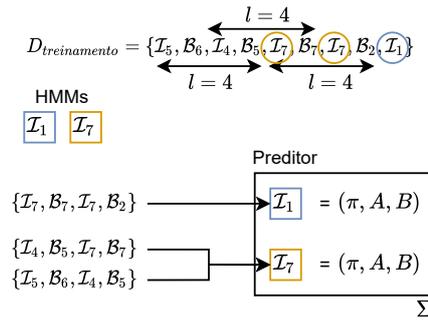


Figura 4.3: Processo de definição da composição do preditor e treinamento.

Após selecionar a quantidade de HMMs que irão compor o preditor, iniciamos a definição das sequências de treinamento que cada HMM receberá. Para isso, utiliza-se os l elementos anteriores a ocorrência do elemento \mathcal{I} para o qual se pretende identificar. Para ilustrar o processo de seleção das sequências de treinamento, retornamos ao exemplo da Figura 4.3. Neste caso o preditor possuirá duas HMMs, uma que reconhecerá o elemento \mathcal{I}_1 e outra que reconhecerá o elemento \mathcal{I}_7 . Como neste exemplo o valor de l escolhido é 4, as duas primeiras ocorrências de \mathcal{I} não possuirão HMM no preditor porque não possuem histórico de elementos suficientes para treinamento. A cada ocorrência de uma mesma duração o histórico de tamanho l é incluído como insumo para treinamento da respectiva HMM. No exemplo da Figura 4.3, como há duas ocorrências do elemento \mathcal{I}_7 na sequência de treinamento, a HMM que reconhece esta duração será treinada com duas sequências, formadas pelos l elementos imediatamente anteriores a cada uma das ocorrências. Neste preditor a quantidade de sequências de treinamento de cada HMM é definida pela quantidade de ocorrências de cada duração no conjunto destinado ao treinamento. Na Seção 4.2 apresentaremos duas modificações na escolha das sequências de treinamento para melhorar o desempenho do preditor.

O algoritmo utilizado para treinamento de cada HMM com base nas sequências foi detalhado na Seção 2.5.4. O treinamento resulta em um conjunto $\Sigma = \{\sigma_1, \sigma_2, \dots, \sigma_\tau\}$

contendo τ HMMs treinadas. Salientamos que o interesse deste trabalho é prever os períodos em que o canal está desocupado, por isso o treinamento é feito para que as HMMs reconheçam apenas os elementos da sequência que representam o canal desocupado.

Como vimos na Seção 2.5.4 o custo em tempo para treinamento de uma HMM λ e uma sequência de tamanho l é dado por $O(N^2l)$, sendo N o número de estados escondidos na HMM λ . Considerando a composição sugerida na Seção 4.1 e o processo de treinamento do preditor apresentado na Seção 4.1.4, o preditor é treinado executando-se o algoritmo de Baum-Welch [88] τ vezes. Cada HMM no preditor requer uma única execução do algoritmo para ser treinada, independentemente do número de sequências de treinamento na entrada daquela HMM [113]. Portanto, o custo computacional do preditor elaborado é $O(\tau N^2l)$. O custo computacional de treinamento do preditor com HMM é independente do número de sequências de treinamento disponíveis.

4.1.5 Procedimento de Previsão

Depois do treinamento, os dados de ocupação do canal são direcionados para o bloco memória. Sua função é armazenar os últimos l elementos da sequência D que serão utilizados para a realização da previsão. Os dados da sequência D são continuamente disponibilizados para este bloco, onde os últimos l elementos são armazenados. Esta memória está configurada para funcionar como uma fila, ou seja, ao receber um novo elemento para armazenamento o elemento mais antigo é descartado. A ordem dos elementos na memória é importante, então este bloco precisa manter os elementos na ordem em que foram recebidos, quando forem utilizados para a previsão.

Digamos que d_n é o último elemento da sequência D no instante de tempo n . Sendo F uma sequência que representa os elementos armazenados na memória, temos que $F = \{d_{n-l}, \dots, d_n\}$. Do mesmo modo, quando for disponibilizado um novo elemento da sequência, no tempo $n + 1$, podemos representar os elementos armazenados na memória como $F = \{d_{n-l+1}, \dots, d_{n+1}\}$.

O bloco de *Previsão* recebe duas entradas: o conjunto Σ contendo todas as HMMs treinadas e a sequência F , com l elementos armazenados. Essas duas entradas são utilizadas para realizar a previsão da duração da próxima oportunidade, representada por \hat{d} . Com estas informações é possível calcular a probabilidade de observação da sequência F para cada uma das HMMs em Σ , conforme descrito na Seção 2.5.3. Este procedimento é similar ao proposto nos artigos [114, 23].

Para cada HMM em Σ , calculamos a probabilidade de observação $P(F|\lambda)$ conforme definido na Equação 2.18, onde F é a sequência armazenada no bloco memória e λ é o conjunto de parâmetros que definem a HMM. Esta probabilidade é calculada com o algoritmo Baum-Welch Forward [114]. Para obter uma estimativa para \hat{d} com a indicação

da duração do próximo período em que o canal estará desocupado, selecionamos a HMM que retornou a maior probabilidade $P(F|\lambda)$. Podemos definir matematicamente este problema como:

$$\hat{d} = \arg \max_{i=\{1,\dots,\tau\}, \lambda_i \in \Sigma} \log P(F|\lambda_i). \quad (4.1)$$

A estimativa \hat{d} é a indicação do preditor para a duração do próximo período em que o canal estará desocupado. Desta forma, um SU poderia usar esta indicação para realizar acesso ao canal. Na seção seguinte iremos propor e detalhar duas modificações no formato de treinamento que beneficiam o SU que utiliza o preditor proposto em duas frentes: menor interferência com as comunicações do PU e melhor aproveitamento das oportunidades disponíveis.

4.2 Aprimoramento do Preditor com HMM

Nesta Seção nos dedicamos a apresentar duas modificações propostas no processo de treinamento das HMMs do preditor, com o objetivo de melhorar seu desempenho. Os aprimoramentos sugeridos atuam na escolha do conjunto de treinamento do processo definido na Seção 4.1.4. No Capítulo 5 veremos que a aplicação destes aprimoramentos modifica o comportamento do preditor de modo que o resultado indica menos interferência com o PU e melhor aproveitamento das oportunidade disponíveis.

4.2.1 Limite de Treinamento - TL

Considerando o processo de treinamento definido na Seção 4.1.4, percebemos que o quantitativo total de HMMs que compõem o preditor é dependente da sequência disponível para treinamento. De maneira análoga, a quantidade de sequências de treinamento disponíveis para cada uma das HMMs também pode variar de acordo o comportamento do PU. Considere que em uma sequência de treinamento, a ocorrência de cada duração entre cinco e oito *slots* está distribuída conforme a Figura 4.4. Certas durações de ociosidades ocorrem mais do que outras, como é o caso da \mathcal{I}_8 , que ocorreu 57 vezes nesta sequência de treinamento. É possível que outras durações ocorram durante o período delimitado para observação do canal para treinar o preditor. Nos limitamos a analisar quatro durações para diminuir a complexidade da técnica a ser apresentada.

Um conjunto de treinamento que possui diferença significativa na quantidade de amostras entre suas classes é considerado um conjunto de treinamento desbalanceado [115]. Para tratar esse tipo de conjunto de treinamento, usualmente são empregados métodos de reamostragem como sub-amostragem [116] e sobre-amostragem [117]. A sub-amostragem foi explorada por García-Moral e Peláez-Moreno [118] ao modificar o treinamento de uma

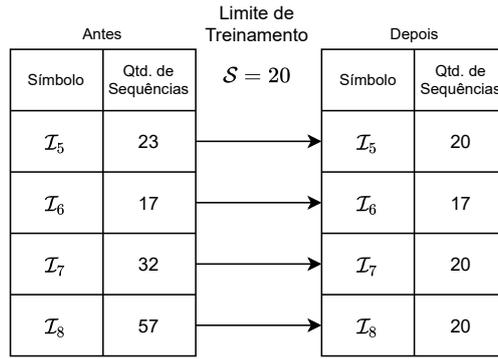


Figura 4.4: Quantidade de ocorrências de cada duração da ociosidade entre cinco e oito *slots*.

Rede Neural Artificial (RNA) reconhecimento automático de discurso, de modo que cada classe fosse treinada com o mesmo número de amostras. Os resultados obtidos mostraram que as RNAs treinadas com o mesmo número de amostras por classe tiveram desempenho similar ou superior com um tempo de treinamento 18 vezes menor, se comparadas as RNAs treinadas com todo o conjunto de treinamento disponível. A sobre-amostragem foi explorada por Sun *et al.* [119] ao treinar um comitê composto por SVM para classificação textual. O treinamento com um conjunto balanceado obteve melhor desempenho em aplicações para classificação textual [120], detecção de padrão em eletrocardiogramas [121] e reconhecimento automático de discurso [118]. O objetivo principal do aprimoramento detalhado nesta seção é equalizar a quantidade de sequências de treinamento utilizadas para treinamento de cada HMM no preditor de forma a obter um conjunto de treinamento balanceado. Desta forma o **Limite de Treinamento (TL)** impõe um limite máximo de sequências que poderão ser utilizadas para treinamento, de modo que as ocorrências adicionais não serão utilizadas. A Figura 4.4 exemplifica o uso, ao se fixar um limite máximo de 20 sequências. Perceba que a duração \mathcal{I}_8 , que inicialmente fora treinada com 57 sequências passa a ser treinada com apenas 20. O mesmo limite é imposto para as durações \mathcal{I}_5 e \mathcal{I}_7 . No caso da duração \mathcal{I}_6 a quantidade de sequências não foi alterada, já que não atingiu o limite estabelecido.

A estratégia adotada neste trabalho seleciona as primeiras sequências do período de treinamento para uso. Há, portanto, espaço para novas avaliações a respeito da representatividade destas sequências e a seleção do conjunto ótimo para uso durante o treinamento. Infelizmente, por restrições de tempo, estas questões serão avaliadas em trabalhos futuros.

4.2.2 Controle de Treinamento - TC

Como verificamos na Seção 4.2.1, um preditor que possui HMMs treinadas com diferentes quantidades de sequência pode gerar previsões tendenciosas [115]. Dessa forma, o preditor resultante da aplicação do TL, exemplificado na Figura 4.4, pode gerar previsões viciadas por conta do treinamento da HMM que reconhece a duração \mathcal{I}_6 , que foi treinada com menos sequências do que as demais. Esta seção apresenta o **Controle de Treinamento (TC)**, o qual visa remover do preditor as HMM que não tiverem um número mínimo definido de sequências de treinamento. Veja o exemplo da Figura 4.5, no qual o controle de treinamento é aplicado considerando um limite mínimo de 20 sequências. Como a HMM que reconhece a duração \mathcal{I}_6 tem apenas 17 sequências, esta HMM não é treinada (\square representa um conjunto vazio de sequências de treinamento).

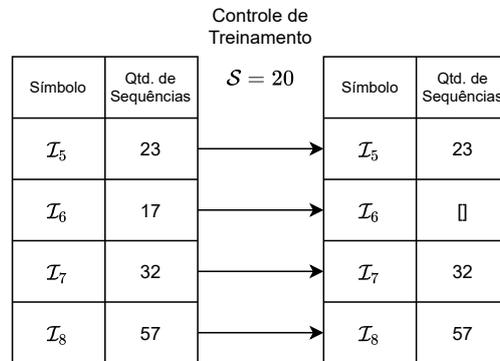


Figura 4.5: Quantidade de ocorrência de cada duração da ociosidade entre cinco e oito *slots*.

Como o TC modifica a composição do preditor removendo HMMs, o número total de HMMs do preditor que aplicar este aprimoramento será reduzido pelo número de símbolos que não satisfizer a condição do número mínimo de ocorrências. Portanto, sendo I_{tc} o número de durações cuja quantidade mínima de sequências \mathcal{S} não foi alcançada, o número final de HMMs no preditor será $\tau - I_{tc}$.

O TC pode ser aplicado individualmente, como é o caso da Figura 4.5, ou em conjunto com TL. O exemplo da Figura 4.6 ilustra a aplicação conjunta de TL+TC, de forma que o resultado é um preditor no qual todas as HMMs foram treinadas com a mesma quantidade de sequências.

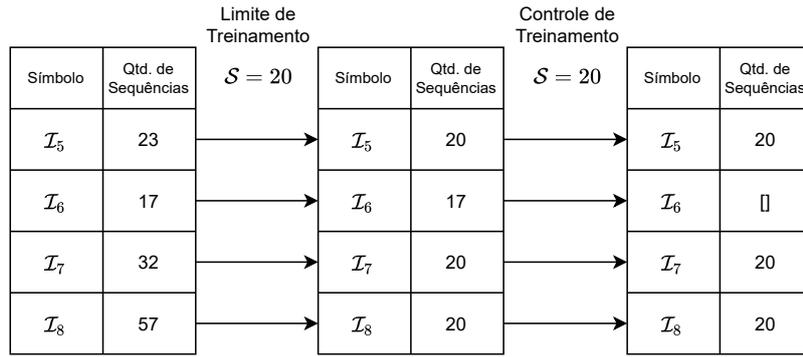


Figura 4.6: Exemplo de utilização conjunta de TL+TC, com $\mathcal{S} = 20$.

Os limites do TL (máximo) e do TC (mínimo) podem ser diferentes, porém o preditor final pode não satisfazer a condição de que todas as HMMs do preditor sejam treinadas com a mesma quantidade de sequências. Neste caso, o preditor pode ainda ter algum grau de desbalanceamento. Por esta razão, no restante deste trabalho consideramos que os limites dos dois aprimoramentos são iguais, fixados por \mathcal{S} , quando aplicados de forma conjunta.

4.3 Previsão de Ocupação do Espectro com RF

Nesta seção apresentaremos um novo preditor, elaborado com base na técnica de aprendizado de máquina conhecida como Floresta Aleatória. Iremos nos referir a este novo preditor, no restante deste trabalho, como preditor baseado em floresta aleatória ou preditor com RF. No melhor do nosso conhecimento, não encontramos a utilização de Floresta Aleatória para previsão de espectro de longo prazo. A escolha dessa técnica está alicerçada no fato de que, como um modelo de comitê, o modelo treinado é menos susceptível a problemas causados pelas características do conjunto de treinamento [81], como o sobre-ajuste (*overfitting*) e pontos fora da curva (*outliers*). Inicialmente indicaremos as semelhanças que este preditor mantém com o preditor com HMM apresentado na Seção 4.1, e como a sequência de treinamento é modelada para formar as estruturas de dados necessárias para o treinamento do preditor baseado em floresta aleatória. Indicaremos também o processo adotado para avaliação dos dados históricos de ocupação para que o preditor baseado em floresta aleatória indique a duração em que o canal estará desocupado.

4.3.1 Treinamento da Floresta Aleatória

Em formato semelhante ao utilizado no preditor com HMM, o preditor com RF foi elaborado de forma que ele pudesse avaliar a sequência da saída do bloco de extração de

tamanhos. Mantendo o mesmo formato do modelo do sistema apresentado na Figura 4.1, adaptando apenas o conjunto de saída do bloco de treinamento. O bloco de treinamento será responsável pelo treinamento das diversas árvores de decisão que compõem a floresta aleatória a partir do conjunto $D_{treinamento}$. O processo de treinamento da Floresta Aleatória está ilustrado na Figura 4.7. Mantendo a notação utilizada na Seção 2.6.1, o vetor \bar{x} é composto por l elementos da sequência $D_{treinamento}$ que antecedem a ocorrência do símbolo \mathcal{I} . O símbolo \mathcal{I} correspondente é o mapeamento na variável de saída Y . Sendo o conjunto de treinamento $D_{treinamento} = \{\mathcal{I}_5, \mathcal{B}_6, \mathcal{I}_4, \mathcal{B}_5, \mathcal{I}_7, \mathcal{B}_7, \mathcal{I}_7, \mathcal{B}_2, \mathcal{I}_1\}$, podemos formar $X = \{\bar{x}_1, \bar{x}_2, \bar{x}_3\}$ conforme apresentado na Figura 4.7. A entrada X pode ser, portanto, mapeada nos elementos $Y = \{\mathcal{I}_7, \mathcal{I}_7, \mathcal{I}_1\}$. A dupla X e Y compõem o conjunto de treinamento da Floresta Aleatória.

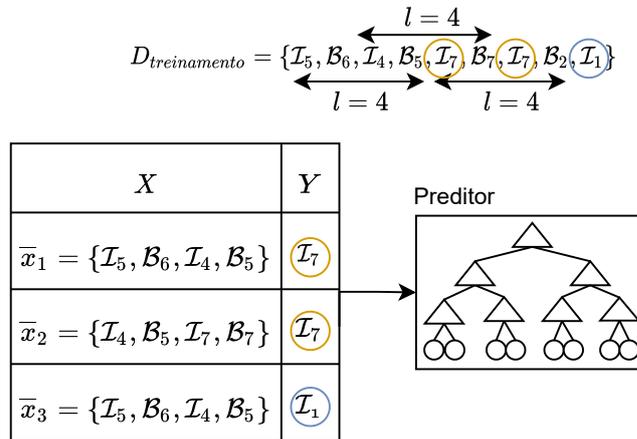


Figura 4.7: Exemplo de formação das variáveis de treinamento da floresta aleatória a partir da sequência $D_{treinamento}$.

Cada árvore da Floresta Aleatória será treinada com um subconjunto dos vetores X e Y formados a partir da sequência de treinamento $D_{treinamento}$. Em cada árvore, a busca dos parâmetros ótimos para a estrutura da árvore é feita com base no erro de classificação aplicando validação cruzada. O erro de classificação é calculado conforme especificado na Equação 2.27. A configuração da árvore que gerar o menor valor para E é incluída na Floresta.

Como vimos na Seção 2.6.2 o custo computacional em tempo para execução do treinamento é $O(vpk \log^2 k)^1$, onde v é o número de árvores de decisão, p é o número de variáveis selecionadas no método *subspace sampling* e k é o número de amostras de entrada no conjunto de treinamento.

¹Seguimos a notação onde $\log^2 x = \log x \times \log x$.

4.3.2 Previsão Utilizando Florestas Aleatórias

Com a Floresta Aleatória formada, o processo de previsão consiste em avaliar um conjunto de entrada \bar{x} contendo l elementos e indicar qual é a classe a qual a entrada está associada. Este processo é executado percorrendo os nós da árvore até que uma folha seja encontrada. A classe a qual a folha escolhida estiver associada é indicada como saída da previsão daquela árvore. Este processo é executado com todas as árvores da Floresta Aleatória. O procedimento de agregação adotado é por votação da maioria, ou seja, a classe que for indicada pela maioria das árvores será escolhida como resultado indicado pelo preditor.

4.4 Métricas de Avaliação

Definiremos nesta seção as métricas de avaliação que serão utilizadas neste trabalho. Estas métricas serão utilizadas para avaliar o desempenho dos preditores apresentados na Seção 4.1 e na Seção 4.3, bem como os aprimoramentos sugeridos para o preditor com HMM na Seção 4.2. Como o formato dos preditores elaborados indicam a duração em que o canal estará desocupado, trataremos inicialmente da classificação da previsão realizada como indicativo da precisão do preditor. Em seguida, nos dedicamos a uma classificação dos *slots* considerando um cenário de compartilhamento do canal entre o PU e o SU. Essa classificação permite avaliar o impacto causado pelo SU ao PU e a efetividade do SU no aproveitamento das oportunidades disponíveis.

4.4.1 Classificação da Previsão

Ao realizar uma previsão utilizando os preditores descritos na Seção 4.1 e na Seção 4.3, um SU obterá uma estimativa da duração em que o canal permanecerá desocupado. Neste sentido, podemos medir a precisão do preditor avaliando a diferença entre a estimativa indicada pelo preditor e o tempo em que o canal permaneceu no estado desocupado. A Figura 4.8 apresenta os três casos em que uma previsão pode ser categorizada. Considere que o comportamento do PU em um canal monitorado pelo SU seja o representado na sequência de *slots* A. Ao realizar uma previsão, o SU poderá prever exatamente o quantitativo de *slots* vagos, subestimar ou sobre-estimar. Estes casos estão representados pela Previsão 1, Previsão 2 e Previsão 3, respectivamente.

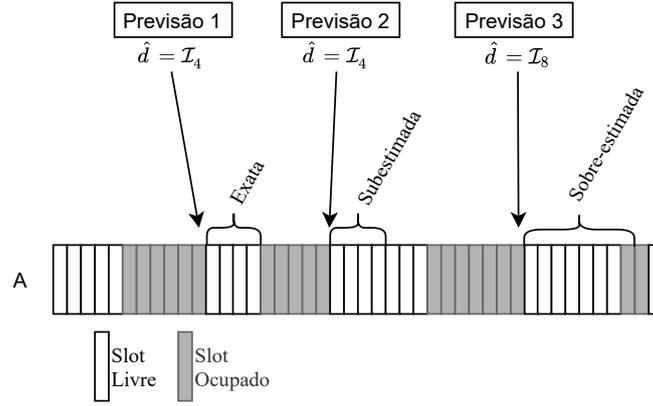


Figura 4.8: Definição de previsão exata, previsão subestimada e previsão sobre-estimada e classificação dos *slots* após tentativa de uso do SU.

Considerando que o SU realizou k previsões e d_n representa a quantidade de *slots* disponíveis no período $n \in \{1, 2, \dots, k\}$. Podemos classificar a estimativa de duração no período n , \hat{d}_n , como:

$$\text{Prev}(\hat{d}_n) = \begin{cases} \text{Exata} & \text{se } \hat{d}_n = d_n \\ \text{Subestimada} & \text{se } \hat{d}_n < d_n \\ \text{Sobre-estimada} & \text{se } \hat{d}_n > d_n \end{cases} \quad (4.2)$$

Por fim, para uma avaliação estatística, calculamos o Erro Quadrático Médio (do inglês, *Mean Square Error* - MSE) (do inglês, *mean-squared error* - MSE) entre a saída do preditor (\hat{d}_n) e a duração do período desocupado do canal (d_n). Formalmente, podemos calcular o MSE como:

$$\text{MSE} = \frac{1}{k} \sum_{i=1}^k (d_i - \hat{d}_i)^2, \quad (4.3)$$

onde k representa o número total de previsões realizadas, d_i a duração do período desocupado, em *slots*, e \hat{d}_i a previsão. Essa métrica tem o objetivo de medir a diferença entre a previsão e a duração atual do período de ociosidade do canal.

4.4.2 Classificação dos *slots*

Como vimos na seção anterior, a previsão realizada pelo SU pode ser classificada em três tipos: previsão exata, previsão subestimada e previsão sobre-estimada. Nesta seção nos dedicaremos a especificar métricas para medir o resultado do compartilhamento do canal entre o PU e o SU, sendo que o SU obtém estimativas da duração do período desocupado a partir dos preditores propostos neste trabalho.

A Figura 4.9 ilustra o resultado do compartilhamento do canal entre o PU e o SU. Utilizaremos o mesmo comportamento do PU e as mesmas previsões da Figura 4.8. A sequência A representa o uso do canal antes do compartilhamento e a sequência B após o compartilhamento. As previsões Exatas (Previsão 1) e as previsões Sobre-estimadas (Previsão 3) geram o aproveitamento de todas as oportunidades daquele período de ociosidade, enquanto que as previsões Subestimadas (Previsão 2) garantem apenas o aproveitamento parcial. Os *slots* vagos, considerados cada um como uma oportunidade para o SU, podem ser classificados como Oportunidade Perdida ou Oportunidade Aproveitada. Uma oportunidade é dita perdida se, após a tentativa de uso do SU, o *slot* continuou vago (sem uso pelo PU e pelo SU). Oportunidades aproveitadas são aqueles *slots* que o SU conseguiu efetivamente utilizar, utilizando o preditor. Para os *slots* inicialmente ocupados pelo PU, estes podem ser categorizados em duas situações após o compartilhamento: a primeira agrupa os *slots* nos quais apenas o PU realizou transmissões (PU Tx); a segunda, agrupa os *slots* nos quais tanto o PU quanto o SU transmitiram (PU SU Tx).

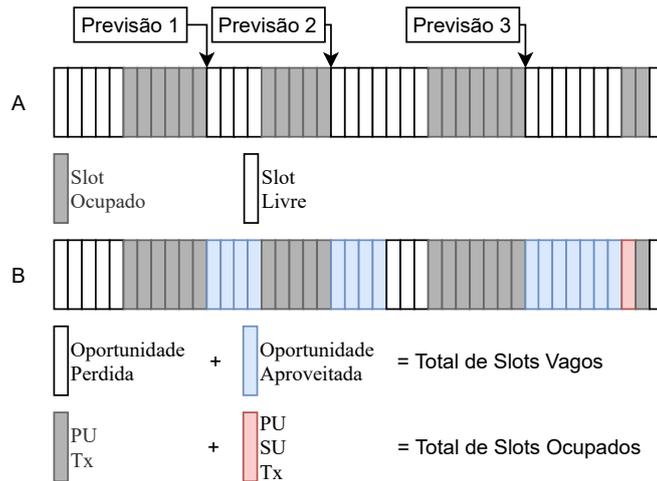


Figura 4.9: Resultado do compartilhamento do canal entre o PU e o SU.

Desta forma, seja w a quantidade total de *slots* vagos em um período definido de observação, w_{perd} a quantidade de oportunidades perdidas e w_{aprov} a quantidade de oportunidades aproveitadas, de modo que $w = w_{perd} + w_{aprov}$. Podemos calcular a taxa de oportunidades disponíveis aproveitadas W como:

$$W = \frac{w_{aprov}}{w_{aprov} + w_{perd}}. \quad (4.4)$$

De modo semelhante, considerando que b é a quantidade de *slots* ocupados pelo PU em um período definido de observação. Sendo b_{PU} a quantidade de *slots* que apenas o PU realizou transmissões e b_{PU+SU} a quantidade de *slots* que o SU realizou transmissões

ao mesmo tempo que o PU, de modo que $b = b_{PU} + b_{PU+SU}$. Podemos definir a taxa de colisão C como sendo:

$$C = \frac{b_{PU+SU}}{b_{PU+SU} + b_{PU}}. \quad (4.5)$$

Conforme definido por Chatziantoniou [122], replicamos a seguir as definições das métricas de avaliação para as previsões realizadas. A taxa de falso positivo é a probabilidade de prever um canal não ocupado como estando ocupado, e a taxa de verdadeiro positivo é a probabilidade de prever um canal ocupado como estando ocupado. A taxa de falso positivo pode ser calculada como $1 - W$. A taxa de verdadeiro positivo pode ser calculada como $1 - C$.

4.5 Métrica de Avaliação Objetiva de Desempenho

Na seção anterior definimos as métricas de avaliação que serão utilizadas como indicadores de desempenho dos preditores elaborados. Porém, as métricas estabelecidas medem componentes diferentes do desempenho de um preditor. Por exemplo, ao avaliar a Taxa de Colisão, medimos o nível de interferência que o SU causou ao PU. Ao avaliar somente o valor obtido em C , não é possível medir quanto o SU foi capaz de aproveitar o canal para suas próprias transmissões. Essa medida está presente na métrica W . A definição desta metodologia se apoia no fato de que para definir o melhor preditor, dentre os disponíveis dadas as várias configurações estudadas, precisamos definir qual é o cenário de compartilhamento e o nível de restrição imposta ao SU. Por um lado, podemos pensar que a escolha da menor taxa de colisão seria a ideia óbvia. Porém, ao analisar o aproveitamento das oportunidades disponíveis pelo SU, a escolha pode não ser tão direta. Por isso, sugerimos uma forma de avaliação que levará em consideração as restrições impostas pelo modo de compartilhamento do canal a que o SU está submetido. A seguir, definimos uma métrica de avaliação e analisamos os cenários de aplicação.

4.5.1 Motivação

Na Seção 4.4 definimos Erro Quadrático Médio (do inglês, *Mean Square Error* - MSE) (MSE) como medida da precisão da estimativa de duração do tempo em que o canal estará desocupado. Definimos também a Taxa de Colisão (C) e a Taxa de Aproveitamento de Oportunidades (W) como medidas do resultado do compartilhamento do canal entre o SU e o PU. Neste compartilhamento, as restrições impostas ao SU, em termos de taxa de colisão, estão diretamente ligadas ao cenário no qual ele está inserido e o modo com que o SU e o PU compartilharão o canal. Retomando os conceitos detalhados na Seção 2.2.3,

onde detalhamos as abordagens de compartilhamento de canal no modelo hierárquico. Considerando um cenário onde o modo de compartilhamento aplicado é o *underlay*, um SU poderá transmitir simultaneamente com o PU se mantiver a interferência abaixo de um limite preestabelecido. Na abordagem *interweave* do modelo hierárquico o SU busca transmitir em momentos em que o PU não está utilizando o canal. Assumimos, no escopo deste trabalho, que ao ocorrerem transmissões simultâneas o SU não é capaz de decodificar os dados no receptor, ou seja, a interferência causada pelo PU no SU impede que o SU receptor receba corretamente os dados enviados.

Em resumo, para melhor entendimento:

1. Na abordagem *underlay* as transmissões do SU são realizadas com potência restrita e a interferência causada no PU é limitada;
2. Na abordagem *interweave* o SU busca não realizar transmissões simultâneas com o PU;

No abordagem *underlay*, o PU tolera bem transmissões do SU no mesmo *slot* ou mesmo estas transmissões são imperceptíveis para o PU. Nestes cenários, é provável que a potência utilizada pelo SU seja muito menor do que a utilizada pelo PU, mantendo o nível de interferência em um patamar suportado pelo PU. Neste contexto, o SU pode adotar estratégias agressivas com objetivo de maximizar a quantidade de oportunidades aproveitadas e por consequência a quantidade de dados transmitidos.

Na abordagem *interweave*, o PU têm baixa tolerância a transmissões do SU no mesmo *slot*. Quando isto acontece é possível que com transmissões concorrentes as transmissões do PU possam ser comprometidas, e por isso devem ser evitadas. Quando um SU está sob este nível de restrição, é importante que a técnica de previsão busque evitar ou diminuir a taxa de colisão ao menor valor possível.

4.5.2 Formulação

Considerando os cenários de compartilhamento descritos, o PU e o SU se beneficiam quando o valor de C é menor. Do ponto de vista de um SU em um canal compartilhado, quanto maior W , melhor o benefício obtido ao realizar previsões. Neste sentido, é lógico pensar que um SU buscará aproveitar tantas oportunidades de utilização do canal quantas estiverem disponíveis. Com isto em mente, conforme ilustrado na Figura 4.10, considere que o valor ideal de W seja 1 (representando o aproveitamento total das oportunidades) e o valor ideal de C seja 0 (representando nenhuma colisão com o PU). Sendo assim, definimos a Métrica de Avaliação Objetiva de Desempenho (MAOD) como a distância ponderada do valor ideal de C e W , portanto:

$$\text{MAOD} = \alpha \times (1 - W) + (1 - \alpha) \times C, \quad (4.6)$$

onde W é a Taxa de Aproveitamento de Oportunidades, C é a Taxa de Colisão e α é o peso atribuído à distância do valor de W até o seu valor ideal. Como $W \in \{0, 1\}$, $C \in \{0, 1\}$ e $\alpha \in \{0, 1\}$, temos que $\text{MAOD} \in \{0, 1\}$.

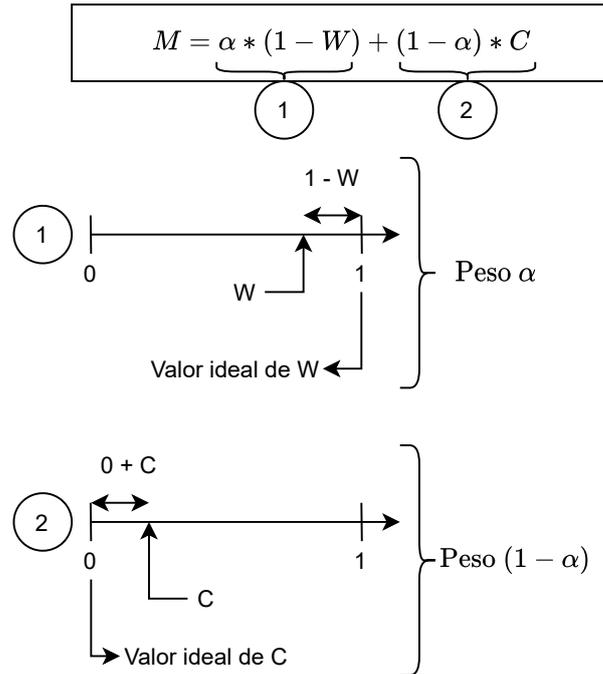


Figura 4.10: Motivações para os componentes da métrica MAOD. (1) Distância ponderada do valor ideal de W . (2) Distância ponderada do valor ideal de C .

Neste contexto, α pode assumir valores no intervalo $\{0, 1\}$, de modo a satisfazer os vários níveis tolerância que o PU apresentar. O parâmetro α pode ser visto como o peso dado à distância de W ao seu valor ideal, de modo que quanto maior o valor de α , maior a influência da distância W do valor ideal no valor da métrica MAOD. Por outro lado, se o objetivo é que a distância de C ao seu valor ideal exerça maior influência na métrica MAOD, basta reduzir o valor atribuído a α . A definição de MAOD nesse formato leva em consideração a diversidade de cenários em que esta técnica pode ser aplicada. Em casos de maior restrição de colisões com o PU, um SU pode ajustar o valor de α de modo a priorizar/reduzir a taxa de colisão. No limite, escolhendo $\alpha = 0$, a métrica buscaria a configuração que minimizaria a taxa de colisão. Desta mesma forma, em um cenário no qual o PU é agnóstico a interferência, o SU pode adotar a estratégia que maximize o aproveitamento das oportunidades escolhendo $\alpha = 1$. Neste cenário, porém, apresentam-

se alguns desafios. Um deles está relacionado ao gasto energético do SU durante uma interferência com o PU. Ao transmitir conjuntamente com o PU em um *slot*, o SU utiliza energia para transmissão sem conseguir nenhuma transferência de dados efetiva.

4.6 Discussão

Neste capítulo detalhamos os preditores elaborados que serão utilizados nos próximos capítulos. Especificamos a transformação realizada na caracterização da ocupação do canal e como os preditores foram adaptados para que pudessem indicar por quanto tempo o canal permanecerá desocupado. Ao avaliar o custo computacional necessário para treinamento dos preditores, vimos que a complexidade em tempo do preditor com RF possui dependência logarítmica com o tamanho do conjunto de treinamento. Por outro lado, a complexidade em tempo do preditor com HMM no formato elaborado é independente do tamanho do conjunto de treinamento. Ambos os preditores dependem linearmente da sua composição. A complexidade de treinamento do preditor com HMM cresce de forma linear dependendo do número de HMMs que compõem o preditor e o preditor com RF cresce de forma linear dependendo do número de árvores de decisão na Floresta Aleatória.

Como mostra a literatura, o desbalanceamento na quantidade de amostras de treinamento entre as diferentes classes de um modelo de aprendizado de máquina pode ser um problema [115]. Para mitigar os efeitos do desbalanceamento no preditor com HMM, dois mecanismos de otimização do treinamento foram propostos. Do ponto de vista de complexidade computacional, a aplicação do aprimoramento TL não altera a complexidade do treinamento. Por outro lado, o número de HMMs na composição do preditor utilizando o aprimoramento TC é sempre menor ou igual ao número de HMMs antes da aplicação do limite. Sendo assim, a complexidade computacional de um preditor utilizando TC é potencialmente menor do que o preditor treinado sem a aplicação do aprimoramento.

Este capítulo também estabelece os critérios de avaliação que serão aplicados de forma a permitir a medição da efetividade dos preditores propostos. Mostramos também que as métricas C e W, no formato especificado neste trabalho, são compatíveis com métricas encontradas na literatura. Por fim, apresentamos a proposta de uma métrica de avaliação pondera os valores obtidos de C e W. Apresentamos também sua utilização de modo a permitir a seleção do preditor para cada cenário.

Capítulo 5

Resultados com Tráfego Sintético

Este Capítulo dedica-se a apresentar os resultados de simulação obtidos com o preditor apresentado no Capítulo 4. Inicialmente definimos o cenário de simulação onde o comportamento do PU é definido por uma distribuição de Poisson, gerados de forma sintética. Neste cenário, avaliamos o preditor baseado em HMM e o efeito dos aprimoramentos propostos na Seção 4.2, à luz das métricas definidas na Seção 4.4. Mostramos também o uso da métrica MAOD, definida na Seção 4.5, para a escolha do melhor preditor no cenário definido. Em seguida, apresentamos uma avaliação do impacto da ocupação do canal pelo PU no desempenho do preditor e no processo de escolha do preditor adequado com a métrica MAOD.

5.1 Metodologia

Nesta seção iremos detalhar a metodologia a ser utilizada para avaliação do preditor proposto no Capítulo 4. A Figura 5.1 apresenta as etapas do processo a ser adotado. Inicialmente definimos as características do comportamento do PU no canal. Ao definir as características do PU, os conjuntos de treinamento e teste serão gerados de acordo com as diretrizes estabelecidas. Em seguida definimos as características dos preditores que serão utilizados, definindo os limites de estudo para todos os parâmetros de configuração. Com essas duas definições, executamos o procedimento de treinamento e seleção do melhor preditor, conforme Seção 4.5. Em seguida, o preditor selecionado será utilizado para realizar previsões em conjuntos de dados destinados à etapa de testes, e o desempenho será medido de acordo com as métricas especificadas na Seção 4.4.

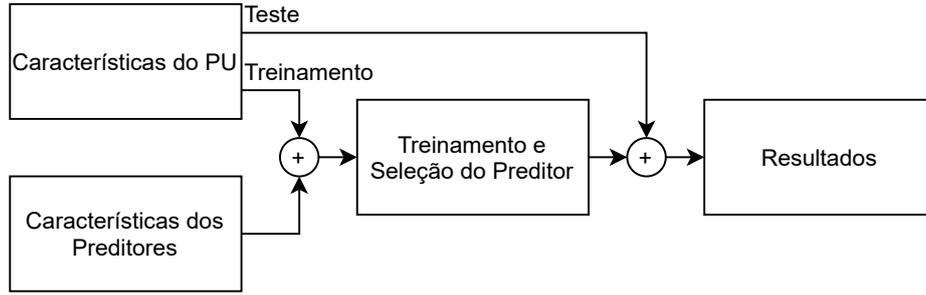


Figura 5.1: Metodologia de avaliação dos preditores.

5.2 Previsão de Ocupação com Tráfego Sintético

Nesta Seção utilizaremos a metodologia definida na Seção 5.1 para avaliar o desempenho de diversas configurações do preditor com HMM, quando o PU ocupa o canal 50% do tempo. Neste cenário, mostraremos que as melhorias propostas na Seção 4.2 são capazes de melhorar o desempenho da previsão, reduzindo a quantidade de colisões e melhorando o aproveitamento das oportunidades.

5.2.1 Caracterização do PU

Para caracterizar o comportamento do PU, sete conjuntos diferentes da sequência D foram gerados no MATLAB, seguindo uma distribuição de Poisson com média 50, cada um contendo 10.000 amostras. A distribuição de Poisson de uma variável aleatória X , com média z possui a seguinte equação, sendo x o valor que a variável aleatória X assume em um ponto, e e a constante de Euler¹:

$$P(X = x) = e^{-z} \frac{z^x}{x!}. \quad (5.1)$$

A distribuição de Poisson foi utilizada por Akbar *et al.* [24] e Paisana *et al.* [123] para caracterização do comportamento do PU. Cada amostra representa a duração, em *slots*, de cada período ocupado ou livre do canal. A taxa de ocupação do canal pelo PU está fixada em 50% no cenário avaliado, e foi alcançada utilizando o mesmo valor de média nas duas distribuições. A Tabela 5.1 sintetiza as configurações que serão utilizadas neste cenário de simulação.

¹A distribuição de Poisson é comumente escrita como $P(X = x) = e^{-\lambda} \frac{\lambda^x}{x!}$. Como utilizamos λ para outro propósito neste trabalho, substituímos a média por z .

Tabela 5.1: Características do cenário de simulação.

Parâmetro	Valor
Quantidade de amostras para treinamento	20.000 - 2 conjuntos de 10.000
Quantidade de amostras para teste	50.000 - 5 conjuntos de 10.000
Duração das ociosidades	Distr. de Poisson com média 50 <i>slots</i>
Duração dos períodos ocupados	Distr. de Poisson com média 50 <i>slots</i>
Ocupação do canal pelo PU	50%

Em cada conjunto, consideramos que o SU observou o canal durante um período necessário para obter 5.000 durações de ociosidades e 5.000 durações de períodos ocupados. Desta forma, cada conjunto será composto por 10.000 elementos no total. Dois conjuntos são destinados à etapa de treinamento. O primeiro deles será destinado para a etapa de treinamento dos preditores, conforme procedimento da Seção 4.1.4, e o segundo será utilizado para a seleção do melhor preditor. A Figura 5.2 apresenta a distribuição das durações das ociosidades e das durações dos períodos ocupados utilizadas para treinamento e para seleção do melhor preditor. A mesma característica das distribuições de Poisson foi aplicada para a geração dos cinco conjuntos destinados à etapa de teste.

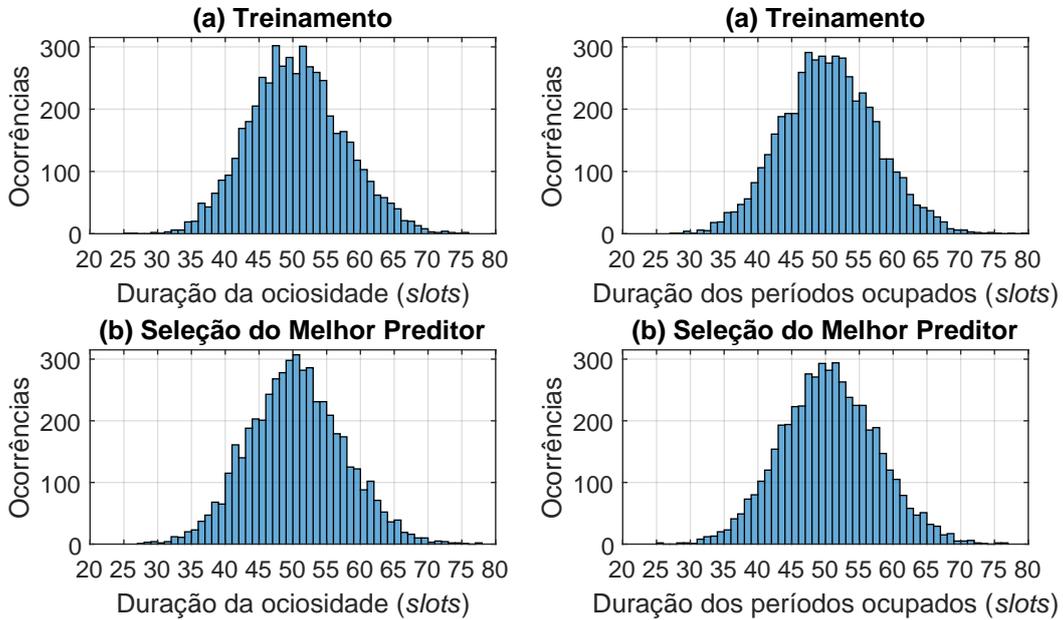


Figura 5.2: Quantidade de ocorrências das durações das ociosidades e dos períodos de ocupação do canal na (a) sequência de treinamento e na (b) sequência de seleção do melhor preditor.

5.2.2 Características dos Preditores

Como vimos no Capítulo 4, o preditor com HMM pode ser configurado para avaliar l elementos no treinamento e no processo de previsão da duração do período de ociosidade do canal. Portanto, quando aplicamos diferentes valores de l para realizar o treinamento do preditor geramos preditores distintos. Para o mesmo valor de l , a introdução dos aprimoramentos sugeridos na Seção 4.2 permite escolher entre quatro formas de aplicação dos aprimoramentos. Um total de 80 preditores distintos foram gerados seguindo as características apresentadas na Tabela 5.2. Para cada tipo de treinamento, variamos o tamanho da sequência de avaliação l entre 1 e 20. Serão avaliados 20 preditores com o treinamento Padrão, 20 preditores com o treinamento TL, 20 preditores com o treinamento TC e 20 preditores com o treinamento TL+TC. Para esta primeira análise, o preditor será configurado para utilizar 2 estados escondidos em cada HMM e $\mathcal{S} = 50$ para aplicação dos aprimoramentos TC e TL (definidos na Seção 4.2).

Tabela 5.2: Características dos preditores que serão avaliados.

Parâmetro	Valor
Quantidade de Estados Escondidos na HMM	2 estados
Limite de Treinamento para TL	50 sequências
Limite de Treinamento para TC	50 sequências
Tamanho da Sequência de Avaliação (l)	$1 \leq l \leq 20$
Tipos de Treinamento	Padrão, TL, TC e TL+TC

5.2.3 Treinamento e Seleção do Preditor

Todos os preditores especificados na Seção 5.2.2 são treinados com o primeiro conjunto de treinamento. Os preditores treinados são utilizados para realizar previsões no segundo conjunto de treinamento e o desempenho em termos de C , W e MSE é medido. Os resultados obtidos estão apresentados na Figura 5.3 e, por representarem os resultados obtidos em um único conjunto, não possuem intervalo de confiança. Os resultados mostram que o preditor padrão apresenta resultado inferior nos valores de MSE , taxa de colisão e taxa de oportunidades aproveitadas para todas as configurações de duração da sequência de avaliação l . Ao aplicar o aprimoramento TL, há uma redução de 7% no valor médio do MSE em relação ao preditor Padrão. Percebemos também uma redução de 1,8% na Taxa de Colisão e um aumento de 0,5% na Taxa de Aproveitamento de Oportunidades, se comparados aos melhores valores de C e W obtidos pelo preditor Padrão. Ao aplicar o aprimoramento TC, percebemos uma redução de 52% no valor médio do MSE . Além disso, esse preditor é capaz de reduzir em 5,2% a Taxa de Colisão e aumentar em 4,5% a Taxa

de Aproveitamento de Oportunidades em relação aos melhores valores obtidos pelo preditor Padrão. A aplicação conjunta dos dois aprimoramentos gera resultados equivalentes à aplicação apenas do TC, em termos de MSE. A redução no valor médio do MSE em relação ao preditor Padrão é da ordem de 50%. Esse preditor também é capaz de reduzir a Taxa de Colisão em 9,7% e aumentar a Taxa de Aproveitamento de Oportunidades em 4,1% em relação aos melhores valores obtidos pelo preditor Padrão.

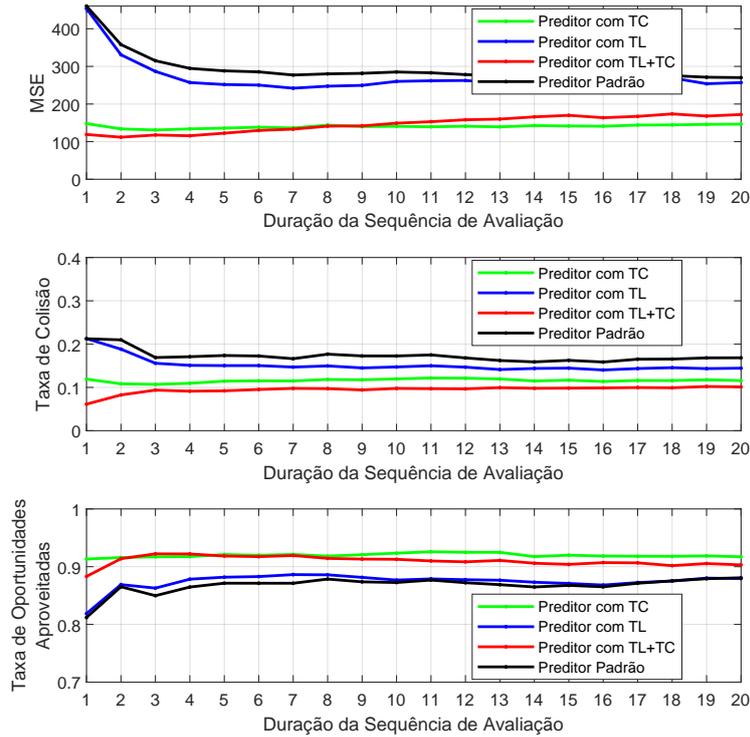


Figura 5.3: MSE, taxa de colisão e taxa de oportunidades aproveitadas para o preditor padrão, para os preditores utilizando os aprimoramentos TL e TC, individualmente e em conjunto.

Desta forma, mostramos que a aplicação dos aprimoramentos propostos traz benefício tanto para o SU quanto para o PU. Mesmo na abordagem de compartilhamento *underlay*, uma menor taxa de colisão possibilita que o SU reduza seu gasto energético, de modo a evitar realizar transmissões em conjunto com o PU. Tais transmissões resultam em gasto energético sem possibilitar transferência efetiva de dados/pacotes pelo SU. Na abordagem *interweave*, o objetivo é que o SU realize suas transmissões nos momentos em que o PU não esteja utilizando. Portanto, menor taxa de colisão é benéfica para ambos os atores do compartilhamento. Da mesma forma, ao possibilitar um maior aproveitamento das oportunidades existentes pelo SU, esse se beneficia com maior uso do canal compartilhado.

O inequívoco benefício gerado com a aplicação dos aprimoramentos percebida na Figura 5.3 nos encaminha a outro desafio: escolher a configuração que melhor se adéqua

ao cenário. Considere o caso estudado anteriormente no qual a utilização do canal pelo PU foi configurada para 50% e $\mathcal{S} = 50$. Considere que o objetivo é escolher, dentre os valores apresentados na Figura 5.3, a melhor configuração de l . A Figura 5.4 apresenta o valor calculado da métrica MAOD, para cada um dos quatro tipos de preditores. Na ideia introduzida na Seção 4.5, quando menor o valor da métrica MAOD menor é a distância ponderada dos valores ideais de C e de W. A ponderação escolhida emprega $\alpha = 0,5$, de modo que os dois componentes tenham o mesmo peso no cálculo da métrica. Portanto, o procedimento de escolha da configuração busca o menor valor da métrica.

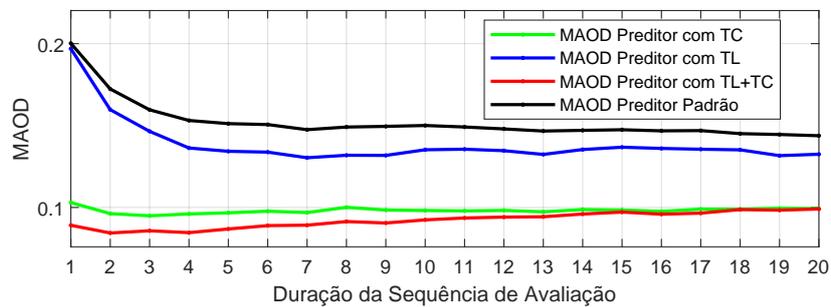


Figura 5.4: MAOD para o cenário em que o PU ocupa o canal em 50% do tempo e $\mathcal{S} = 50$.

Na Tabela 5.3 listamos os 5 melhores resultados, os valores obtidos para C e W e a configuração do preditor. Alinhado com os resultados da Figura 5.3, os melhores resultados são obtidos ao utilizar o preditor com TL+TC, dentre os quais o melhor resultado é obtido com a utilização de uma sequência de tamanho $l = 2$. Por utilizar $\alpha = 0,5$, o procedimento sugerido busca escolher valores intermediários para C e W, balanceando bons resultados na taxa de colisão e no aproveitamento das oportunidades.

Tabela 5.3: Cinco melhores resultados de MAOD para $\alpha = 0,5$ e $\mathcal{S} = 50$.

MAOD	W	C	MSE	Config. Preditor
MAOD = 0,0844	0,9138	0,08260	111,8	TL+TC, $l = 2$
MAOD = 0,0846	0,9220	0,09124	115,6	TL+TC, $l = 4$
MAOD = 0,0858	0,9222	0,09372	117,7	TL+TC, $l = 3$
MAOD = 0,0869	0,9184	0,09212	122,5	TL+TC, $l = 5$
MAOD = 0,0889	0,9174	0,09518	129,7	TL+TC, $l = 6$

Caso ocorra empate na etapa de escolha da configuração do preditor, ou seja, mais de uma configuração retorne o menor valor da métrica MAOD, o critério de desempate escolherá, pela ordem:

1. Escolha a configuração com Treinamento:
 - (a) TL+TC;
 - (b) TL ou TC;
 - (c) Padrão;
2. Escolha a configuração com menor l ;
3. Escolha a configuração com menor \mathcal{S} .

Uma análise similar à elaborada para $\alpha = 0,5$ pode ser utilizada para buscar a configuração que minimiza o valor da métrica MAOD. Outros valores de α podem ser utilizados na estratégia adotada, de modo que a métrica reflita a importância de C e W para o SU. A Tabela 5.4, apresenta os valores de W e C utilizados para cálculo da métrica MAOD, ao utilizar $\alpha = 0$ e $\alpha = 1$. Considere que o SU esteja interessado em escolher uma configuração do preditor de modo a obter a menor taxa de colisão possível. Ao escolher $\alpha = 0$ o preditor escolhido alcança uma taxa de colisão de 5,9%, sendo esta a menor taxa de colisão alcançada. De forma semelhante, se o SU está interessado em obter o melhor aproveitamento das oportunidades, ele pode utilizar $\alpha = 1$, e nesse caso a taxa de uso das oportunidades chega a 92,4%, em contraste aos 88,2% obtidos ao priorizar uma menor taxa de colisão. Conseqüentemente, o resultado é um incremento na taxa de colisão para 11,9%.

Tabela 5.4: Resultado da modificação do peso α e o reflexo na métrica MAOD. Para $\mathcal{S} = 50$.

Peso	W	C	Config. Preditor
$\alpha = 0$	0,8822	0,0590	TL+TC, $l = 1$
$\alpha = 1$	0,9243	0,1198	TC, $l = 11$

Observamos, nos resultados apresentados na Figura 5.3, que o menor valor da Taxa de Colisão (C) é 5,90%, obtida com $l = 1$ aplicando TL+TC. A maior Taxa de Aproveitamento de Oportunidades (W) é 92,43%, obtida com $l = 11$ aplicando apenas TC. Ao selecionar $\alpha = 0$ e $\alpha = 1$, a métrica MAOD indica exatamente a configuração do preditor que gera o melhor resultado em termos de taxa de colisão e taxa de oportunidades aproveitadas, respectivamente. Ao selecionar $\alpha = 0,5$, a métrica assume pesos iguais para

C e W de modo que o melhor resultado conjunto possa ser obtido. Valores intermediários de α podem ser utilizados para priorizar C e W, de forma que o procedimento de escolha da melhor configuração possa ser adaptado para quaisquer restrições que o SU esteja submetido.

Uma avaliação do impacto da escolha do α será realizada na Seção 6.2.5, de modo a entender o comportamento da escolha do preditor ao variar dentro do limite $0 \leq \alpha \leq 1$. Utilizaremos nas Seções seguintes a métrica MAOD para avaliar o desempenho dos preditores em diferentes cenários. Para que a comparação seja adequada, fixamos o valor de $\alpha = 0,5$, de modo que os valores de C e W tenham o mesmo peso.

5.2.4 Resultados da Predição em Tráfego Sintético

Para validar o procedimento adotado na Seção anterior da escolha do melhor preditor, o preditor com a configuração selecionada nos conjuntos de treinamento será utilizado para previsões nos cinco conjuntos de treinamentos disponíveis. A Tabela 5.5 apresenta os resultados obtidos ao realizar previsões com o preditor na configuração TL+TC, $l = 2$, $\mathcal{S} = 50$, no conjunto de testes definido na Seção 5.2.1. Os intervalos de confiança de 95% estão explicitados. Observamos que o resultado obtido no conjunto de testes é muito próximo com o valor obtido no conjunto utilizado para seleção do melhor preditor. Este preditor havia obtido $W = 91,38\%$ e $C = 8,26\%$ no conjunto de treinamento e obteve $W = 91,43\%$ e $C = 8,12\%$ na média dos resultados obtidos nos cinco conjuntos de teste.

Tabela 5.5: Desempenho do melhor preditor no conjunto de testes, utilizando $\alpha = 0,5$ e $\mathcal{S} = 50$.

Preditor	W	C	MSE
TL+TC, $l = 2$, $\mathcal{S} = 50$	$0,9143 \pm 0,0009$	$0,08120 \pm 0,00222$	$108,5 \pm 1,9$

5.3 Influência da Ocupação do PU nas Previsões

Saad *et al.* [124] sugerem que o desempenho do preditor baseado em HMM proposto por eles é melhor quando a ocupação do canal pelo PU é maior. Para avaliar o comportamento do preditor proposto neste trabalho em cenários com diferentes ocupações, variamos a média das distribuições de Poisson que geram as durações dos períodos ocupados e ociosos avaliados. Para cada cenário, utilizaremos a mesma metodologia especificada na Seção 5.1.

5.3.1 Caracterização do PU

Para caracterização do PU com diversas ocupações, em cada cenário, o quantitativo especificado na Tabela 5.8, foi gerado. Mantendo a coerência com o processo realizado na Seção 5.2.1, geramos dois conjuntos de 10.000 amostras destinados ao treinamento e seleção do melhor preditor e cinco conjuntos distintos de 10.000 amostras destinados a etapa de teste.

Tabela 5.6: Quantidade de amostras em cada cenário de ocupação do PU.

Parâmetro	Valor
Quantidade de amostras para treinamento	20.000 - 2 conjuntos de 10.000
Quantidade de amostras para teste	50.000 - 5 conjuntos de 10.000

Para obter a ocupação do canal desejada pelo PU, alteramos as médias das distribuições de Poisson conforme Tabela 5.7. Dessa forma, foram gerados 9 cenários, cuja ocupação do canal pelo PU varia entre 10% e 90%.

Tabela 5.7: Média de Poisson para cada cenário de ocupação do canal pelo PU.

Cenário	Período Ocupado Médio	Período Ocioso Médio
PU ocupação 10%	10 <i>slots</i>	90 <i>slots</i>
PU ocupação 20%	20 <i>slots</i>	80 <i>slots</i>
PU ocupação 30%	30 <i>slots</i>	70 <i>slots</i>
PU ocupação 40%	40 <i>slots</i>	60 <i>slots</i>
PU ocupação 50%	50 <i>slots</i>	50 <i>slots</i>
PU ocupação 60%	60 <i>slots</i>	40 <i>slots</i>
PU ocupação 70%	70 <i>slots</i>	30 <i>slots</i>
PU ocupação 80%	80 <i>slots</i>	20 <i>slots</i>
PU ocupação 90%	90 <i>slots</i>	10 <i>slots</i>

5.3.2 Características dos Preditores

Na Seção 5.2 restringimos a utilização de preditores com $\mathcal{S} = 50$. Para permitir uma avaliação completa, nesta seção utilizaremos valores de \mathcal{S} entre 10 e 100, conforme especificado na Tabela 5.8. Adotaremos a configuração do limite do aprimoramento TC igual ao do aprimoramento TL e serão avaliados os tipos de treinamento Padrão, TL, TC e TL+TC. Os preditores serão compostos por HMMs com dois estados escondidos e o tamanho da

sequência de avaliação está configurada para variar entre $1 \leq l \leq 20$. Considerando os quatro tipos de treinamentos, teríamos, com os limites estabelecidos neste trabalho, a possibilidade de elaborar 800 preditores distintos para avaliar cada cenário (20 tamanhos de sequência de avaliação, 10 diferentes números de sequência de treinamento e 4 métodos de treinamento).

Tabela 5.8: Características do cenário de simulação.

Parâmetro	Valor
Quantidade de Estados Escondidos na HMM	2 estados
Limite de Treinamento para TL	10, 20, 30, 40, 50, 60, 70, 80, 90 e 100
Limite de Treinamento para TC	10, 20, 30, 40, 50, 60, 70, 80, 90 e 100
Tamanho da Sequência de Avaliação (l)	$0 \leq l \leq 20$
Tipos de Treinamento	Padrão, TL, TC e TL+TC

5.3.3 Treinamento e Seleção do Preditor

Os preditores especificados na seção anterior são treinados com um conjunto de amostras destinados a treinamento, em cada um dos cenários. Os preditores são utilizados para realizar previsão no segundo conjunto de treinamento e o desempenho de cada um deles é monitorado. A Tabela 5.9 apresenta a configuração do preditor que obteve a menor métrica MAOD com $\alpha = 0,5$, avaliando-se cada um dos cenários de ocupação entre 10% e 90%. Desta forma, estamos comparando diferentes configurações do preditor baseado em HMM proposto neste trabalho. Perceba que, na maior parte dos cenários, a melhor métrica foi obtida ao se treinar aplicando TL+TC.

Tabela 5.9: Melhor conjunto de parâmetros do preditor para cada cenário de ocupação, com $\alpha = 0,5$.

Cenário	l	S	Treinamento	MAOD
PU ocupação 10%	1	40	TL+TC	0,1635
PU ocupação 20%	1	60	TL+TC	0,1202
PU ocupação 30%	1	100	TL+TC	0,0921
PU ocupação 40%	1	80	TL+TC	0,0785
PU ocupação 50%	1	100	TL+TC	0,0716
PU ocupação 60%	3	100	TL+TC	0,0727
PU ocupação 70%	1	50	TC	0,0689
PU ocupação 80%	4	90	TL+TC	0,0790
PU ocupação 90%	12	80	TL+TC	0,0856

5.3.4 Resultados da Influência da Ocupação do Canal

Para validar o procedimento adotado na Seção anterior da escolha do melhor preditor em cada cenário, o preditor com a configuração selecionada nos conjuntos de treinamento será utilizado para previsões nos cinco conjuntos de treinamentos gerados. A Figura 5.5 apresenta a taxa de oportunidades aproveitadas e a Taxa de Colisão obtidas em cada um dos cenários com os preditores da Tabela 5.9. Notamos que quanto mais o PU ocupa o canal mais dificuldade o SU tem de fazer um uso efetivo das oportunidades disponíveis. Em um cenário onde as oportunidades se apresentam em menor volume, o preditor tende a ser mais conservador na indicação da duração da oportunidade para evitar causar colisões com o PU. O método proposto permite aproveitar mais de 80% das oportunidades existentes mesmo em cenários com alta ocupação do canal.

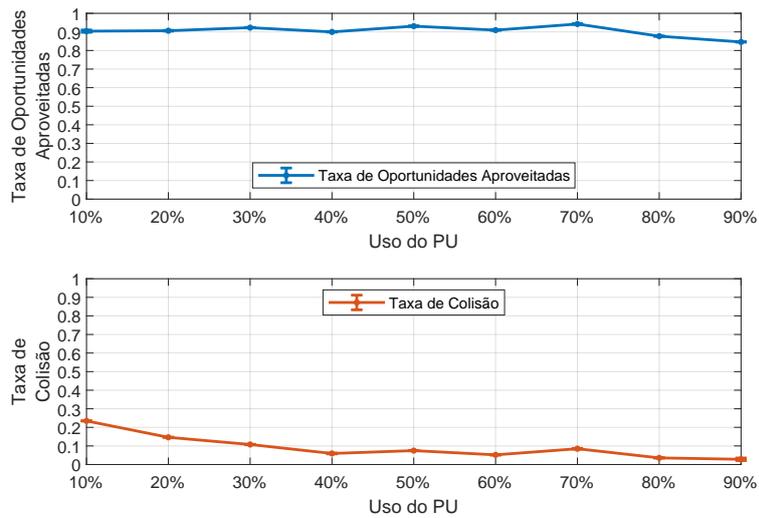


Figura 5.5: Taxa de oportunidades aproveitadas e taxa de colisão para cada cenário de ocupação do PU entre 10% e 90%.

A suposição mencionada em [23], de que em cenários de maior ocupação do canal o preditor teria melhor desempenho, foi parcialmente confirmada. De fato, a Taxa de Colisão reduz a medida que a ocupação do canal pelo PU aumenta. Porém, ao avaliar a quantidade de *slots* vagos aproveitados pelo SU, percebemos que há uma redução do aproveitamento em cenários em que o PU utiliza mais intensamente o canal.

O gráfico da Figura 5.6 apresenta o quantitativo de *slots* vagos presentes em cada um dos cenários. A Figura 5.6(a) mostra uma visão em proporção e a Figura 5.6(b) uma visão em números absolutos. Na Figura 5.6(b) agrupamos no gráfico de barras separadamente os quantitativos de *slots* vagos utilizados e *slots* vagos não utilizados. De forma geral, à medida que as oportunidades se tornam mais escassas, o quantitativo de *slots* vagos não utilizados pelo SU também apresenta redução. Como a quantidade de previsões realizadas é 50.000 (conforme Tabela 5.6) em todos os cenários avaliados, é plausível concluir que as previsões realizadas nos cenários com ocupação acima de 60% estão mais próximas de uma previsão exata do que em cenários com menor ocupação. Essa conclusão vem do fato de que nos cenários com maior ocupação a taxa de colisão é menor e portanto, as previsões sobrestimadas geram colisão com menos *slots* quando elas ocorrem. Outro resultado que contribui para esta conclusão é o valor do Erro Quadrático Médio (do inglês, *Mean Square Error* - MSE) (MSE) das previsões em cada cenário. Para o cenário com 10% de ocupação do canal pelo PU, obtivemos $MSE = 215,42$. Para 50% de ocupação tivemos $MSE = 80,36$ e para 90% tivemos $MSE = 24,85$. Portanto, o valor do MSE reduz consistentemente a medida que a ocupação do canal pelo PU cresce.

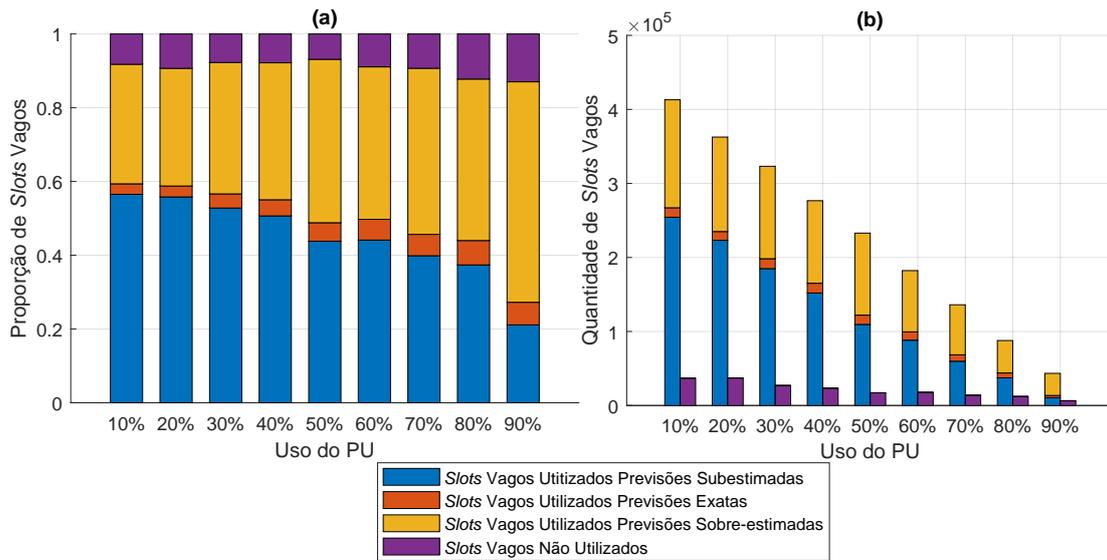


Figura 5.6: Quantidade de *slots* vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e quantidade de *slots* não utilizados. (a) visão em proporção e (b) visão em números absolutos.

Considere os resultados apresentados na Figura 5.5, onde percebemos que a taxa de colisão reduz à medida que o PU faz maior uso do canal (e conseqüentemente a duração das ociosidades é menor). Apesar do quantitativo total de *slots* livres diminuir nesta situação, como vimos na Figura 5.6, o aproveitamento percentual permanece ainda acima dos 80%. Além disso, a taxa de colisão é reduzida para abaixo de 4% no cenário de maior ocupação, em contraste com os 24% obtidos no cenário de menor ocupação. Ao avaliar a métrica MAOD como distância do valor ideal de C e W, percebemos que o menor valor (menor distância do ideal) é obtido no cenário em que o PU ocupa o canal 70% do tempo (conforme Tabela 5.9). Para ocupações maiores, a métrica volta a subir pois nestes casos a Taxa de Oportunidades Aproveitadas apresenta redução maior.

5.4 Discussão

Neste capítulo avaliamos o preditor proposto e seu desempenho quando aplicado a um canal cujo PU segue uma distribuição de Poisson. Validamos também, neste mesmo cenário, a utilização da métrica MAOD na escolha do preditor apropriado ao cenário. Vimos que a escolha do preditor leva a resultados semelhantes aos obtidos no conjunto de treinamento, mesmo quando aplicados a conjuntos diferentes na etapa de teste. Vimos que os aprimoramentos Limite de Treinamento e TC proporcionam ao preditor melhores resultados em termos de Taxa de Colisão (C), Taxa de Aproveitamento de Oportunidades (W) e Erro Quadrático Médio (do inglês, *Mean Square Error* - MSE) (MSE), quando

comparadas à implementação padrão encontrada na literatura. A suposição inicial de que o preditor teria melhores resultados em cenários com maior ocupação do canal [124] foi parcialmente confirmada. Nos cenários com maior ocupação do canal pelo PU o preditor foi capaz de reduzir a Taxa de Colisão em relação aos cenários com menor ocupação, porém a Taxa de Aproveitamento de Oportunidades também apresentou redução nos cenários de uso intenso do canal pelo PU.

Ao estabelecer limites máximos e mínimos, as técnicas TL e TC atuam na quantidade de sequências de treinamento utilizadas para treinar cada HMM do preditor. Neste trabalho, foram selecionadas as \mathcal{S} primeiras sequências de cada duração da ociosidade. A escolha foi feita sem avaliar a representatividade das sequências dentro do conjunto de treinamento. Portanto, outras estratégias de escolha do conjunto de treinamento podem melhorar ainda mais o desempenho do preditor com HMM.

A aplicação da metodologia de escolha do melhor preditor utilizando a métrica MAOD se mostrou efetiva nos cenários avaliados. Porém, os critérios de desempate foram estabelecidos arbitrariamente, balizados pela percepção de esforço computacional requerido. A definição dos critérios de desempate carecem de melhor investigação, considerando o custo computacional de cada algoritmo de forma que o desempate consciente seja possível.

Apesar da implementação nos sugerir que os aprimoramentos e a estratégia de seleção do melhor preditor são efetivos, os resultados se sustentam na premissa de que o comportamento do PU pode ser caracterizado por uma distribuição de probabilidade. No próximo capítulo utilizamos o preditor elaborado neste trabalho e a métrica sugerida para realizar previsões em uma base de dados de coletas reais. O objetivo é validar o funcionamento do preditor em cenários reais e avaliar o efeito da introdução de incertezas do detector no aprendizado validado, até agora, com comportamento sintético do PU.

Capítulo 6

Resultados com Tráfego Real

Este Capítulo dedica-se a avaliar o desempenho do preditor proposto no Capítulo 4 em uma base de dados de coleta com acesso público, contendo amostras de um ambiente real. O preditor proposto foi avaliado no Capítulo 5 com tráfego sintético e obteve bons resultados. Neste capítulo o intuito é validar o preditor em um cenário real. Para fins de comparação, utilizaremos um procedimento de previsão baseado aprendizado de máquina, que será avaliado de forma conjunta nos mesmos cenários disponíveis na base de dados de coleta selecionada. Apresentaremos inicialmente a metodologia a ser utilizada, ressaltando as diferenças em relação ao procedimento definido na metodologia do Capítulo 5. Mostraremos as características da base selecionada e o processo de transformação necessário para adequar o formato dos dados ao formato necessário para os preditores. Após o treinamento dos preditores, faremos uma breve análise do impacto do valor do α nos resultados. Em seguida, apresentamos os resultados obtidos e finalizamos o capítulo aplicando um procedimento de validação cruzada como validação estatística dos resultados obtidos.

6.1 Metodologia

A metodologia adotada neste capítulo é similar à utilizada no Capítulo 5. A modificação da metodologia está relacionada ao bloco Características do PU, conforme detalhado na Figura 6.1. Ao contrário da metodologia adotada no Capítulo 5, na qual adotamos uma geração sintética do comportamento do PU, neste capítulo, o comportamento do PU será definido por uma base de dados pública selecionada. Como os dados da base selecionada não estão no formato adequado para utilização no treinamento e previsão, dois procedimentos foram executados para adequar o formato dos dados. Para tanto, a base de dados de coleta selecionada é submetida a um processo para separação do canal de interesse e em seguida um limiar é definido. Desta forma, teremos uma sequência que

representa a característica de ocupação do canal pelo PU. O restante do procedimento é idêntico ao executado no Capítulo 5.

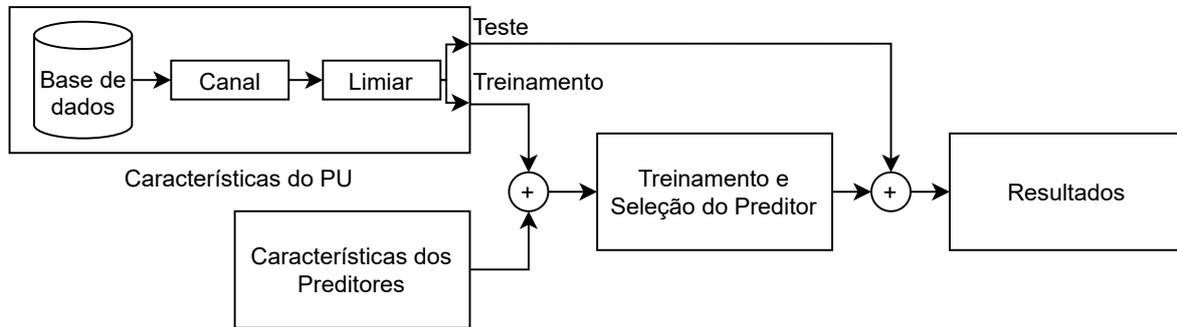


Figura 6.1: Metodologia de avaliação dos preditores na base de dados pública.

6.2 Previsão de Ocupação com Tráfego Real

Com o intuito de avaliar a metodologia de previsão proposta neste trabalho em um cenário real, utilizamos a base de dados disponibilizada por Alvarez [125]. Os dados foram utilizados no desafio DySPAN 2017 [123], no qual foram propostos dois desafios aos participantes. O primeiro desafio era detectar o comportamento do PU no canal dentre um conjunto de comportamentos previamente definidos. O segundo desafio era a utilização oportunista dos *slots* não utilizados pelo PU, de forma oportunista. Os dados disponibilizados caracterizam 10 diferentes comportamentos do PU no canal monitorado. Essa base de dados foi utilizada como treinamento do mecanismo proposto para o desafio DySPAN. As características apresentadas nesta Seção foram extraídas do trabalho publicado por Paisana *et al.* [126]. No restante deste capítulo iremos nos referir a esta base de dados como base DySPAN.

6.2.1 Descrição da base DySPAN

A Figura 6.2 descreve o comportamento esperado do PU e apresenta um trecho da coleta com a visualização de 150ms ($3 \times 50\text{ms}$) para cada um dos dez cenários. Nos cenários 0 e 1, o PU seleciona de forma aleatória um canal e transmite pacotes a cada 5ms e 10ms respectivamente. Em cada período de coleta o PU pode selecionar um canal diferente para transmitir. No cenário 2, o PU seleciona dois canais aleatórios, dentre os quatro disponíveis, e transmite saltando entre esses dois canais com pacotes a cada 5ms. No cenário 3, o PU transmite pacotes a cada 10ms saltando entre os quatro canais disponíveis. No cenário 4, o PU seleciona dois canais aleatórios para transmitir pacotes a cada

5ms nos dois canais ao mesmo tempo (sincronizados). Nos cenários 5 e 6, o PU realiza transmissões sincronizadas em todos os 4 canais com tempo entre pacotes fixo em 5ms e 2ms respectivamente. Nos cenários 7 a 9, a transmissão do PU em cada um dos quatro canais é determinada por uma distribuição de Poisson com média 20ms, 10ms e 5ms respectivamente.

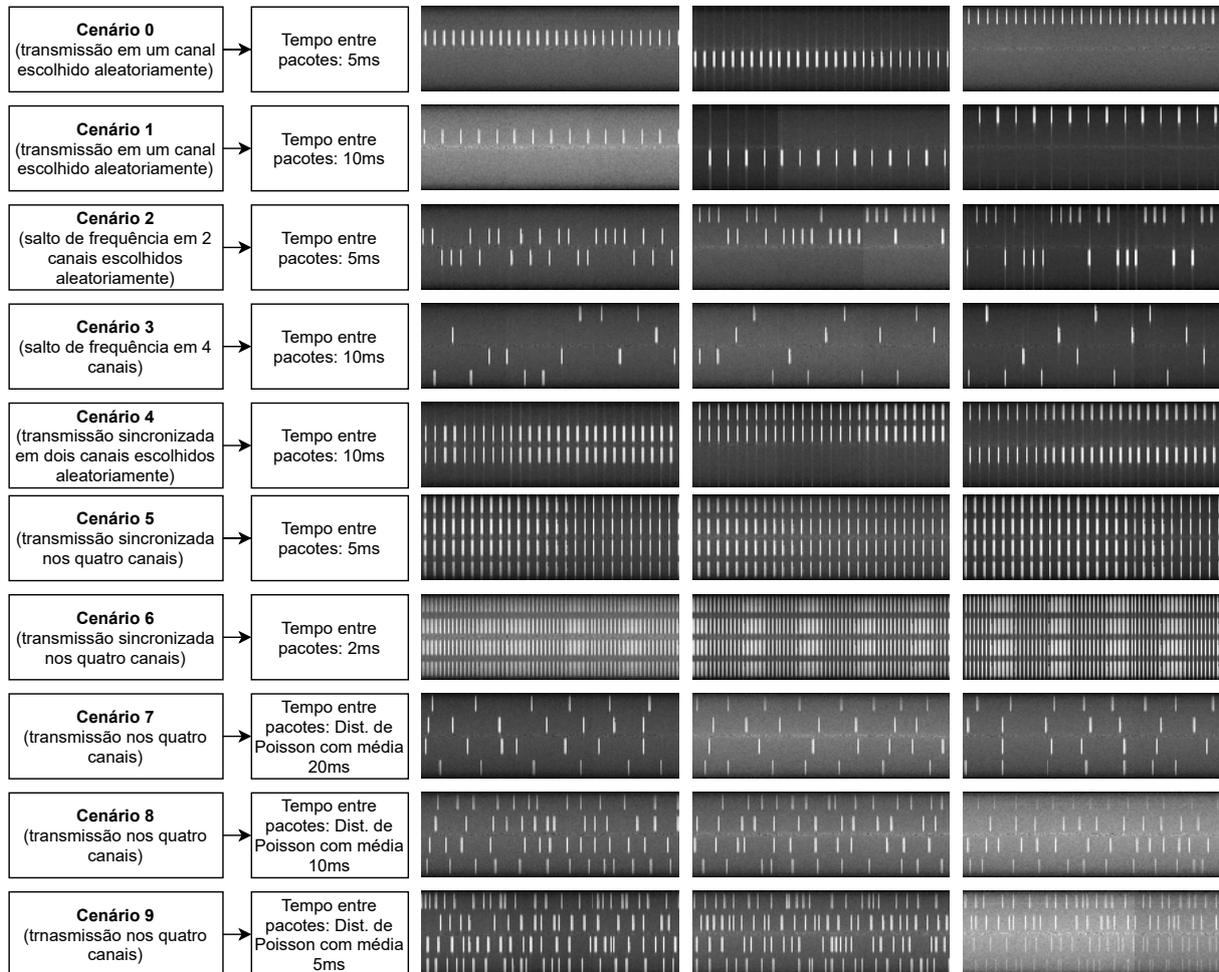


Figura 6.2: Descrição e exemplo de transmissões dos cenários 0 a 9. Visualização de 150ms (3×50 ms) de cada cenário.

Nos cenários de 0 até 4, é necessário identificar em qual dos canais o PU está transmitindo para poder monitorar seu comportamento, por isso optamos, no escopo deste trabalho, por não avaliá-los. Os cenários 5 e 6 fornecem um comportamento determinístico do PU, e portanto teoricamente mais simples para o preditor se adaptar e conseguir boas previsões. Os cenários de 7-9 apresentam cenários mais complexos, nos quais a variabilidade dos períodos sem uso é maior.

Os dados coletados presentes na base DySPAN monitoram quatro canais e foram separados em dois conjuntos: o conjunto de treinamento e o conjunto de teste. No

escopo deste trabalho, selecionamos 1.000 arquivos do conjunto de treinamento e 800 arquivos do conjunto de teste para avaliação, que serão utilizados conforme Figura 6.3. O conjunto de treinamento foi dividido em duas partes, compondo o subconjunto destinado ao treinamento e o subconjunto destinado à seleção do melhor preditor. O conjunto de teste será utilizado integralmente para teste do preditor selecionado.

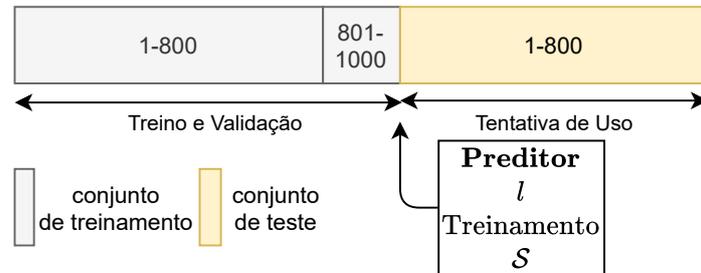


Figura 6.3: Utilização dos conjuntos de treinamento e teste da base DySPAN.

6.2.2 Canalização e Amostragem

A banda total monitorada é de 10MHz, conforme ilustrado na Figura 6.4. Ao todo quatro canais de 2,5MHz são monitorados e estão igualmente distribuídos. A banda total é mapeada em 64 elementos, representando a potência do sinal recebido por um número de 0 a 255. A amostragem do canal é feita a cada 1ms e a cada 64 amostras é gerado um arquivo para armazenamento. Portanto, cada um dos arquivos possui uma matriz com 64 linhas e 64 colunas, onde cada elemento representa a intensidade do sinal recebido. Cada um dos canais é subdividido em três partes: banda de guarda esquerda, banda de guarda direita e banda central. A amostragem das bandas de guarda esquerda e direita estão mapeadas em 5 elementos cada uma, enquanto que a banda central é representada por 6 elementos.

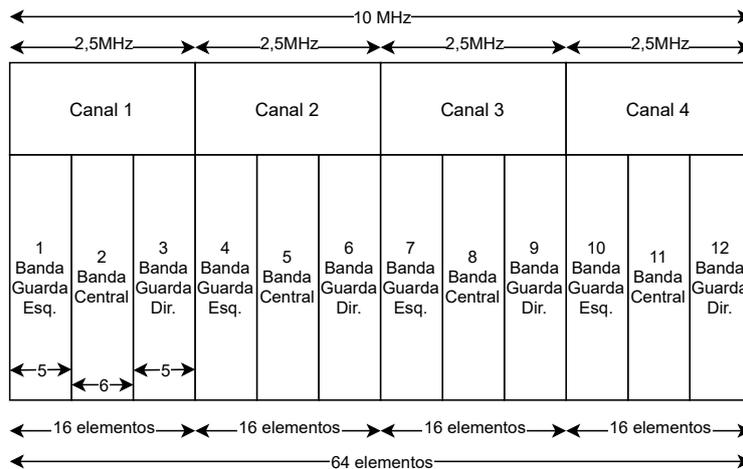


Figura 6.4: Divisão dos quatro canais dispostos na banda monitorada.

Com a delimitação apresentada na Seção 6.1, este trabalho se limitará a avaliar os cenários 5 a 9. Nos cenários 5 e 6 a transmissão do PU em cada um dos canais é sincronizada, ou seja, todos os canais recebem transmissão do PU ao mesmo tempo. Nos cenários 7 a 9, o PU obedece uma distribuição de Poisson para definir o intervalo entre pacotes em cada um dos canais. Nesses casos, as transmissões em cada um dos canais não são sincronizadas. Como o preditor elaborado não está adaptado para tratar cenários com mais de um canal e independente do canal selecionado o comportamento do PU é mantido, escolhemos arbitrariamente o canal 3 para as avaliações que serão conduzidas neste trabalho.

6.2.3 Limiar Dinâmico

Conforme sugerido em [126], a aplicação direta do detector por energia em cada canal poderia gerar um quantitativo grande de falso alarme, ou seja, o detector por energia indicaria o canal como ocupado quando ele está na verdade vazio. A Figura 6.5 ilustra o processo de cálculo da Potência Relativa a partir da amostragem do canal 3. Calcula-se inicialmente a potência das bandas de guarda direita e esquerda e a potência da banda central. Dessa forma, a potência relativa recebida do canal é calculada pela razão entre a potência da banda central e a potência nas bandas de guarda.

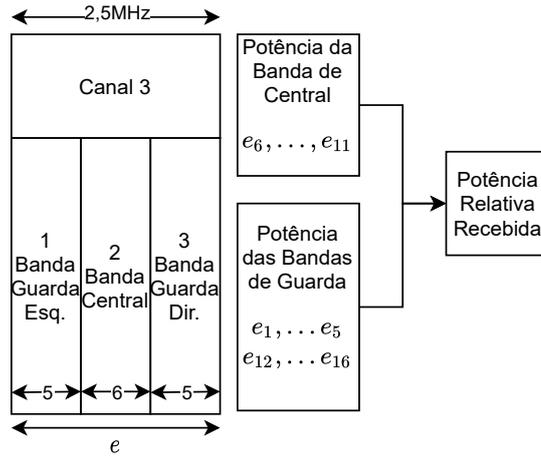


Figura 6.5: Cálculo da potência relativa recebida para o canal 3.

Considere que $e = \{e_1, e_2, \dots, e_{16}\}$ represente o conjunto de elementos de amostragem de um dado canal, onde $\forall e \in \{1, 2, \dots, 255\}$. Podemos calcular a potência das bandas de guarda como:

$$P_{guarda} = \frac{e_1 + e_2 + e_3 + e_4 + e_5 + e_{12} + e_{13} + e_{14} + e_{15} + e_{16}}{10}. \quad (6.1)$$

A potência da banda central, portanto, é calculada como:

$$P_{cent} = \frac{e_6 + e_7 + e_8 + e_9 + e_{10} + e_{11}}{6}. \quad (6.2)$$

A potência relativa recebida (P_{rel}) é a divisão entre a potência da banda central e a média das potências das bandas de guarda direita e esquerda, portanto:

$$P_{rel} = \frac{P_{cent}}{P_{guarda}}. \quad (6.3)$$

No lugar de determinar um limiar fixo para o detector por energia, sugerimos a definição de um limiar dinâmico, dado que a relação sinal-ruído das coletas pode variar significativamente. Para tanto, utilizamos, para cada cenário, um filtro passa baixas. O tipo de filtro, o ganho e a frequência de corte estão apresentadas na Tabela 6.1. Utilizamos a mesma frequência de corte e o mesmo tipo de filtro em todos os cenários, ajustando apenas o ganho do filtro de forma empírica em cada cenário para obter o limiar.

Tabela 6.1: Configuração dos filtros aplicados para definição do limiar nos Cenários 5-9.

Cenário	Tipo de Filtro	Ganho do Filtro	Frequência de Corte
Cenário 5	Passa Baixa	1,05	5Hz
Cenário 6	Passa Baixa	1,00	5Hz
Cenário 7	Passa Baixa	1,07	5Hz
Cenário 8	Passa Baixa	1,06	5Hz
Cenário 9	Passa Baixa	1,06	5Hz

6.2.4 Características dos Preditores

As características dos preditores que serão avaliados neste capítulo estão descritas na Tabela 6.2. Mantendo a coerência com os preditores avaliados no Capítulo 5, as mesmas configurações serão aplicadas nesta avaliação.

Tabela 6.2: Características dos preditores com HMM que serão avaliados.

Parâmetro	Valor
Quantidade de Estados Escondidos na HMM	2 estados
Limite de Treinamento para TL	10, 20, 30, 40, 50, 60, 70, 80, 90 e 100
Limite de Treinamento para TC	10, 20, 30, 40, 50, 60, 70, 80, 90 e 100
Tamanho da Sequência de Avaliação (l)	$1 \leq l \leq 20$
Tipos de Treinamento	Padrão, TL, TC e TL+TC

Com o objetivo de comparar o desempenho do preditor elaborado, aplicaremos também um preditor baseado em floresta aleatória (detalhado na Seção 2.6), para o qual as configurações estão descritas na Tabela 6.3. O algoritmo fará uso de árvores binárias de classificação, no qual o tamanho da sequência de avaliação irá variar entre 1 e 20.

Tabela 6.3: Características dos preditores com floresta aleatória que serão avaliados.

Parâmetro	Valor
Número de Variáveis em Cada Nó de Divisão	entre 1 e 5
Validação Cruzada	<i>k-fold</i> com $k = 10$
<i>Loss Function</i>	<i>Cross Validation Classification Error</i>
Número de Árvores em cada Comitê	100
Método de Agregação	Média
Tamanho da Sequência de Avaliação (l)	$1 \leq l \leq 20$

6.2.5 Treinamento e Seleção do Preditor

Para cada um dos cenários avaliados, o conjunto de treinamento de 1.000 arquivos (equivalente a 64.000 amostras) foi utilizado, sendo 80% das amostras destinadas para treinamento dos preditores e 20% destinadas para a etapa de seleção da configuração do melhor preditor, conforme ilustrado na Figura 6.6.

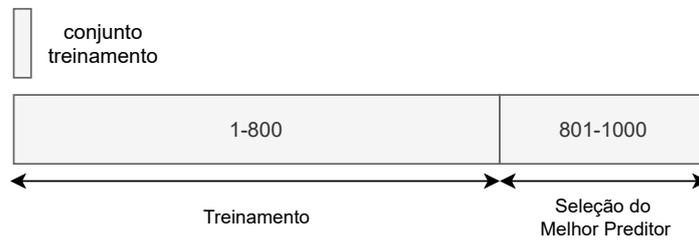


Figura 6.6: Representação do conjunto de treinamento contendo 1.000 arquivos, da divisão proposta e das destinações de cada parte.

Considere que, na etapa de treinamento, a primeira parte do conjunto de treinamento é disponibilizada para as várias configurações possíveis dos preditores com HMM e com RF. Ao todo 400 preditores com HMM e 20 preditores com RF foram treinados em cada um dos cenários. Em seguida, todos os preditores foram utilizados para realizar previsões para a segunda parte do conjunto de treinamento e o desempenho em termos de C , W e MSE foram medidos. Aproveitaremos o cenário descrito para fazer uma análise qualitativa da escolha do valor de α na métrica MAOD. Como brevemente pontuado na Seção 5.2.3, até o momento decidimos fazer uso da métrica MAOD aplicando $\alpha = 0,5$, por entender que este valor busca balancear o desempenho em termos de C e W de forma conjunta.

Para avaliar a escolha do valor do α de forma mais detalhada, a Figura 6.7 apresenta o gráfico de dispersão dos preditores para os cenários 5 e 6, no qual o eixo das abscissas representa o valor de W e o eixo das ordenadas representa o valor de C obtido pelo preditor. A Figura 6.7(a) e a Figura 6.7(c) apresentam os gráficos de dispersão de cada um dos preditores em função dos valores obtidos de C e W , para o cenário 5 e 6 respectivamente. A Figura 6.7(b) e a Figura 6.7(d) apresentam os desempenhos obtidos pelos preditores que foram escolhidos utilizando a métrica MAOD, para valores entre $0 \leq \alpha \leq 1$. Destacamos o desempenho dos preditores escolhidos quando utilizamos $\alpha = 0$ e $\alpha = 1$.

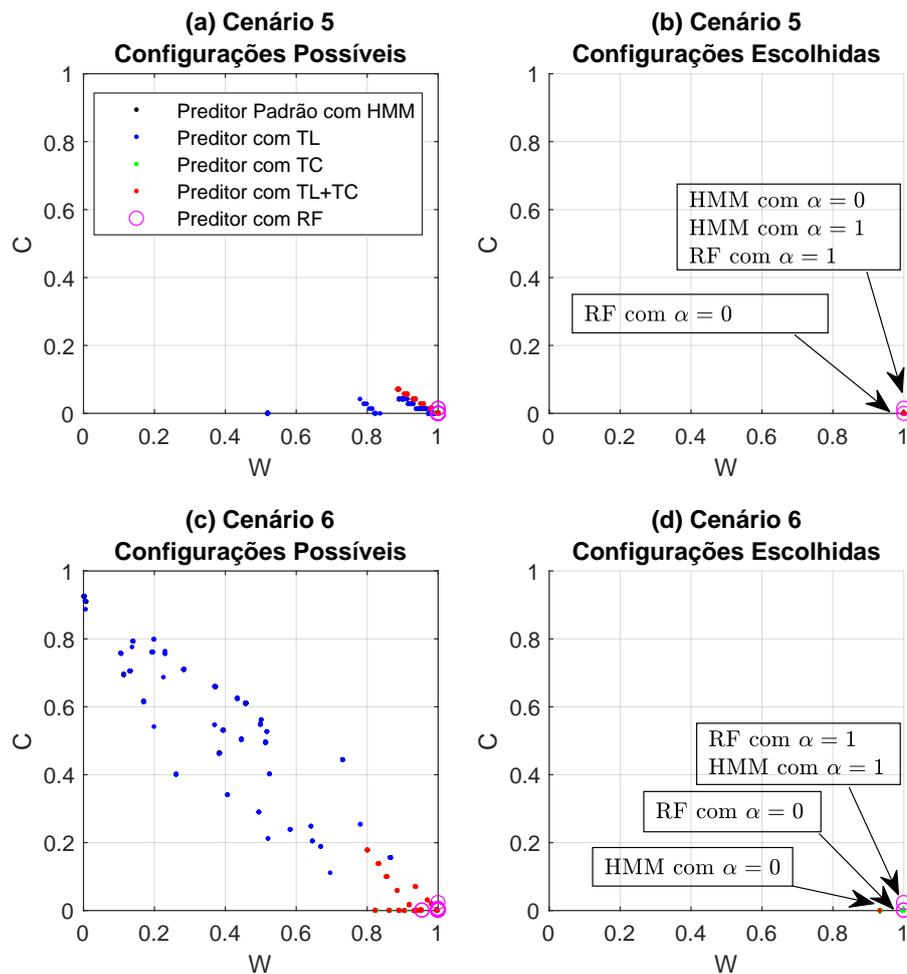


Figura 6.7: Dispersão das diferentes configurações dos preditores em função de C e W . (a) e (c) apresentam todas as configurações possíveis para os cenários 5 e 6. (b) e (d) apresentam as configurações escolhidas ao utilizar a métrica MAOD, para α entre 0 e 1.

Nos dois cenários percebemos, a partir da Figura 6.7(a) e da Figura 6.7(c), que ambos os preditores possuem configurações que obtêm valores de W e C próximos dos seus valores ideais, indicando boa adaptação ambos os cenários. Notamos a variação de desempenho entre os preditores com RF avaliados é pequena, com grande concentração desses próximos

de $W \approx 1$ e $C \approx 0$ também em ambos os cenários. Para os preditores com HMM, há uma variação maior do desempenho percebido, principalmente no cenários 6 onde o intervalo entre pacotes é menor. Porém, com a escolha adequada da configuração do preditor com HMM em cada cenário, é possível escolher preditores que obtém desempenho próximo ou igual aos preditores com RF nos dois cenários. Ao avaliar a Figura 6.7(b) e da Figura 6.7(d), percebemos que, de fato, as configurações escolhidas indicam que o desempenho dos dois preditores, nos dois cenários, são bem próximas mesmo com os diferentes valores possíveis de α .

Estão apresentadas na Figura 6.8 as configurações selecionadas para cada valor de α entre 0 e 1, nos cenários 5 e 6. No eixo x estão dispostos os valores possíveis de α . Por mais que existam várias configurações possíveis, ao utilizar o valor de α nos limites estabelecidos apenas um conjunto desses preditores é escolhido. As Figura 6.8(a) e Figura 6.8(c) apresentam todas as configurações escolhidas dos preditores com HMM e com RF. As Figura 6.8(b) e Figura 6.8(d) apresentam as configurações escolhidas dentre os preditores com HMM e com RF para valores possíveis de α . Foram avaliados os valores de α com precisão de 10^{-4} . Para o cenário 5, o preditor com HMM selecionado é o mesmo independente do valor de α , já o preditor com RF oscila entre duas possíveis configurações, conforme ilustrado na Figura 6.8(b). Ao escolher $\alpha = 0$ para o preditor com RF, a configuração escolhida é a que obtém valores próximos de zero para C e para W (conforme indicado na Figura 6.7(b)). É importante notar que haviam outras escolhas possíveis para este preditor que trariam melhor desempenho em termos de W, mas que foram preteridas ao adotar valores próximos de zero para α . Na Figura 6.7(d), no cenário 6, o mesmo comportamento do preditor com RF é observado para $\alpha = 0$. Conforme indicado na Figura 6.8(b) e na Figura 6.8(d), uma variação pequena de α é suficiente para que uma configuração diferente seja escolhida, em ambos os cenários. Para o preditor com HMM no cenário 6 é possível a escolha de 5 configurações distintas, conforme Figura 6.8(c). Um detalhamento dos intervalos está disponível no Anexo I.

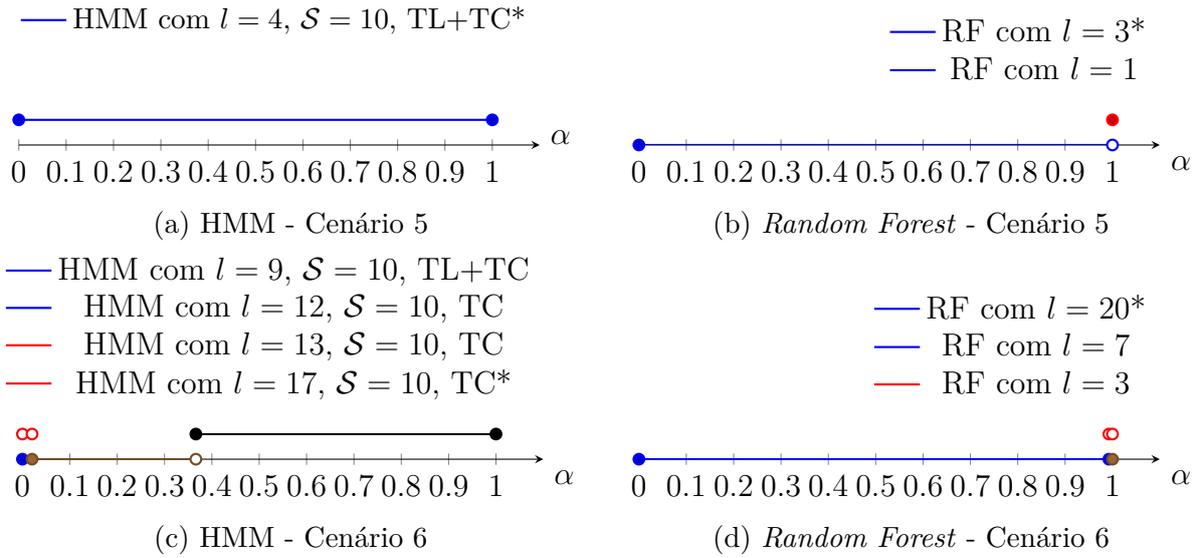


Figura 6.8: Escolha da configuração do melhor preditor em função do valor do α , para os cenários 5 e 6.

Com base ainda nos resultados obtidos ao realizar previsões em 20% das amostras do conjunto de treinamento e encerrando a análise dos cenários 5 e 6, discutiremos agora o que foi considerado para a escolha do valor de α . Podemos calcular a relação entre o benefício obtido pelo SU ao utilizar o canal, representado por W , e o impacto causado ao PU, representado por C . A Tabela 6.4 mostra os intervalos de α em que maximizam o valor $W - C$. Identificamos na Figura 6.8 com um * a configuração do preditor com melhor valor $W - C$. Os valores utilizados desta relação para todos os intervalos de α são apresentados no Anexo I. Podemos perceber que empregar $0,3662 \geq \alpha \geq 0,9923$, para os cenários 5 e 6, a relação $W - C$ obtém seu maior valor independente do cenário e do preditor utilizado.

Tabela 6.4: Intervalos de α no qual a relação $W - C$ obtém seu maior valor para os cenários 5 e 6.

Preditor com	Cenário	Valor Mínimo	Valor Máximo
HMM	Cenário 5	0	1
HMM	Cenário 6	0,3662	1
RF	Cenário 5	0	0,9999
RF	Cenário 6	0	0,9923

A Figura 6.9 apresenta o gráfico de dispersão de cada um dos preditores em função de C e W para os cenários 7, 8 e 9. O eixo das abscissas representa o valor de W e o eixo das

ordenadas representa o valor de C obtido pelo preditor. Nas Figura 6.9(b), Figura 6.9(d) e Figura 6.9(f), estão destacados o desempenho das configurações escolhidas ao utilizar $\alpha = 0$ e $\alpha = 1$. Ao todo, tivemos 5 configurações escolhidas para o preditor com HMM no cenário 7, 3 configurações no cenário 8 e apenas 2 no cenário 9. Para o preditor com RF, 4 configurações distintas são escolhidas ao variar o valor de α entre 0 e 1 para os cenários 6, 3 configuração no cenário 7 e 6 configurações distintas para o cenário 9 (as tabelas contidas no Anexo I apresentam maiores detalhes sobre os intervalos de escolha). O comportamento visto nos cenários 5 e 6 para $\alpha = 0$ no preditor com RF, não se repete para os cenários 7, 8 e 9. Apesar de existir um preditor com RF cujo desempenho foi $W \approx 0$ e $C \approx 0$, este preditor não foi escolhido quando utilizamos $\alpha = 0$ por conta da existência de outro preditor com desempenho $C \approx 0$ e $W = 72,23\%$, $W = 71,84\%$ e $W = 68,62\%$ nos cenários 5, 6 e 7 respectivamente. Apesar da redução no valor de W observada ao utilizar $\alpha = 0$, o preditor com HMM ainda mantém mais 37,5%, 36,71% e 35,26% de aproveitamento nos cenários 5, 6 e 7 respectivamente.

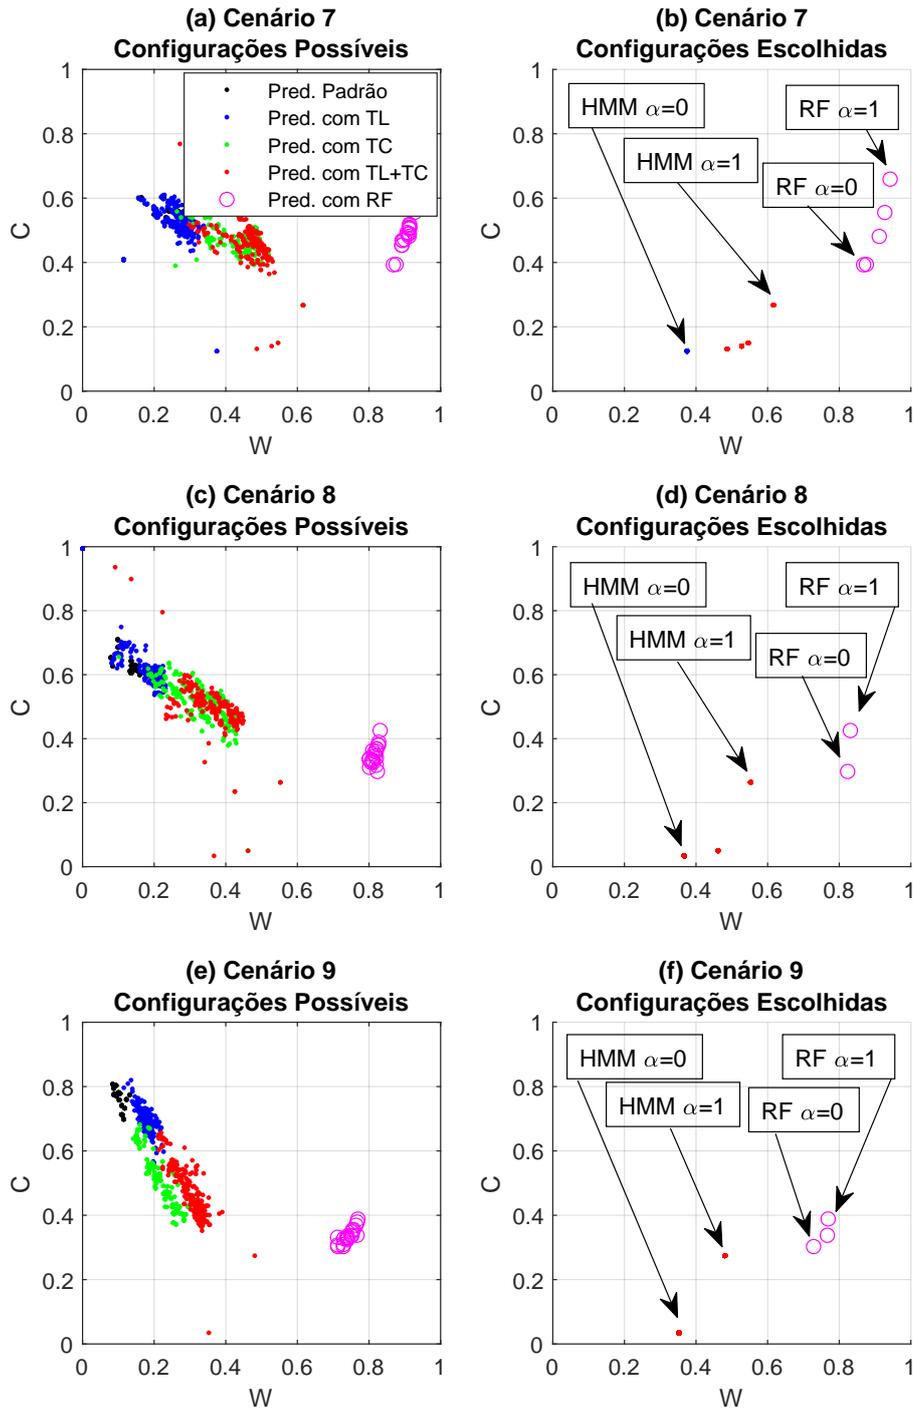


Figura 6.9: Dispersão das diferentes configurações dos preditores em função de C e W. (a), (c) e (e) apresentam todas as configurações possíveis para os cenários 7, 8 e 9. (b), (d) e (f) apresentam as configurações escolhidas ao utilizar a métrica MAOD, para α entre 0 e 1.

Estão apresentadas na Figura 6.10 as configurações selecionadas para cada valor de α entre 0 e 1, nos cenários 7, 8 e 9. No eixo x estão dispostos os valores possíveis de α . A Figura 6.10(a), a Figura 6.10(c) e a Figura 6.10(e) apresentam os intervalos para

o preditor com HMM. A Figura 6.10(b), a Figura 6.10(d) e a Figura 6.10(f) apresentam os intervalos para o preditor com RF. O preditor com RF no cenário 9 é o que tem o maior número de configurações escolhidas no intervalo de α avaliado, com ao todo 6 configurações diferentes. O preditor com HMM no cenário 7 alterna entre 5 configurações distintas, sendo este cenário o que mais teve transições dentre os cenários avaliados com HMM.

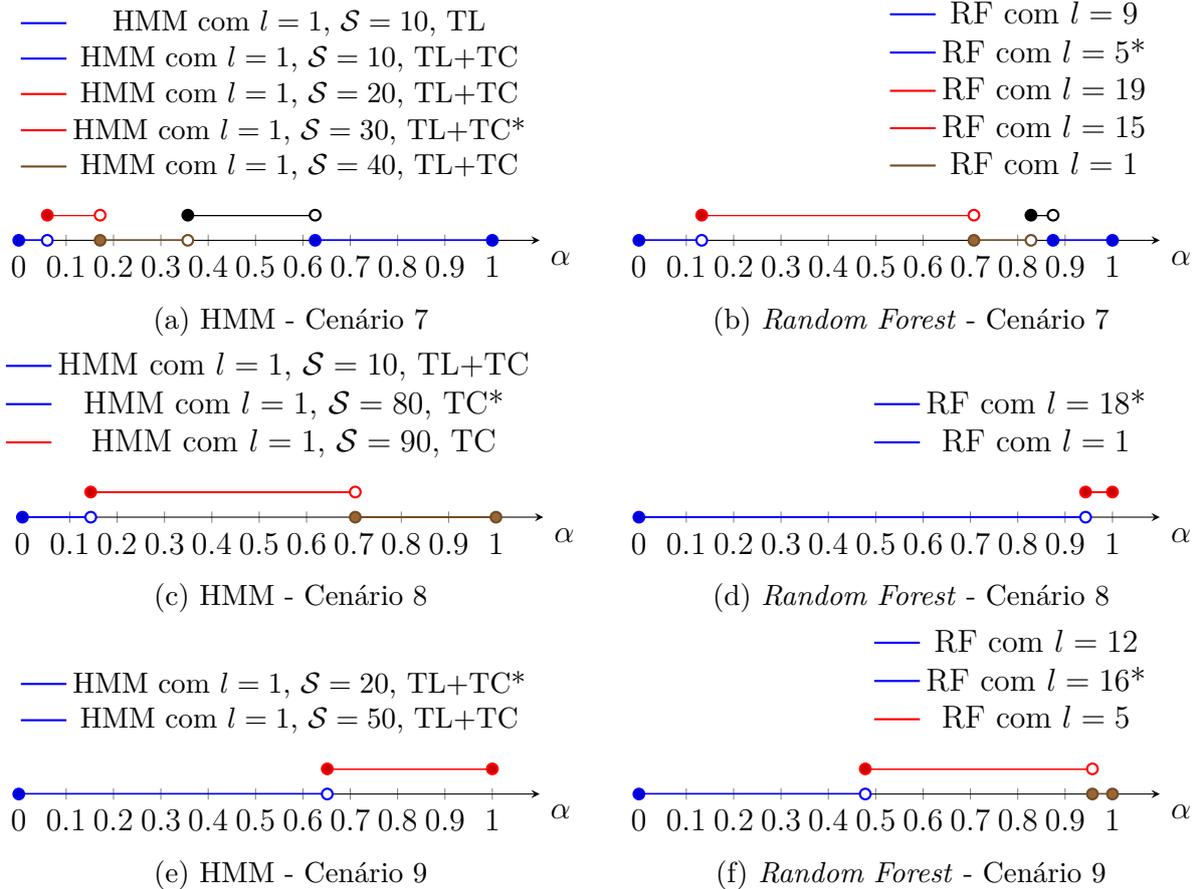


Figura 6.10: Escolha da configuração do melhor preditor em função do valor do α , para os cenários 7 a 9.

A Figura 6.5 apresenta os intervalos de α nos quais a relação $W - C$ obtém seus maiores valores para os cenários de 7 a 9. Estão identificados com * na Figura 6.10 a configuração do preditor que obteve melhor valor para $W - C$. Os valores utilizados para todos os intervalos de α estão apresentados no Anexo I. Ao aplicar $0,4780 \geq \alpha \geq 0,6258$, para os cenários de 7 a 9, a relação $W - C$ obtém seu maior valor para todas as combinações de cenário e preditor avaliadas. Portanto, teremos um melhor preditor com HMM e um melhor preditor com RF para cada um dos cenários. Por fim, se considerarmos que o intervalo obtido para os cenários 7, 8 e 9 está contido no intervalo obtido para os cenários 5 e 6, podemos afirmar que ao empregar $0,4780 \geq \alpha \geq 0,6258$, a relação $W - C$ obterá

seu valor máximo em todos os cenários. Esta generalização pode ser feita apenas para os cenários avaliados da base DySPAN, não sendo esta uma generalização que sirva para qualquer comportamento do PU no canal.

Tabela 6.5: Intervalos de α no qual a relação $W - C$ obtém seu maior valor para os cenários 7, 8 e 9.

Preditor com	Cenário	Valor Mínimo	Valor Máximo
HMM	Cenário 7	0,3569	0,6258
HMM	Cenário 8	0,1442	0,7027
HMM	Cenário 9	0,0000	0,6513
RF	Cenário 7	0,1326	0,7073
RF	Cenário 8	0	0,9432
RF	Cenário 9	0,4780	0,9576

Com as considerações apresentadas para a escolha do valor do α , podemos finalizar o procedimento de escolha do melhor preditor para cada cenário. A partir do desempenho das previsões realizadas nas amostras dos 200 arquivos destinados à escolha, os preditores apresentados na Tabela 6.6 foram escolhidos. Como o objetivo da introdução do preditor com *Random Forest* foi servir como comparação com o preditor com HMM, o processo de escolha do melhor preditor foi realizado separadamente em cada conjunto. Por praticidade, configuramos o valor de $\alpha = 0,5$ para as avaliações que serão feitas no restante deste trabalho.

Tabela 6.6: Melhor conjunto de parâmetros do Preditor para os Cenários 5-9.

Cenário HMM	l	\mathcal{S}	Treinamento	Cenário RF	l
Cenário 5	4	10	TL+TC	Cenário 5	$l = 3$
Cenário 6	17	10	TC	Cenário 6	$l = 20$
Cenário 7	1	40	TL+TC	Cenário 7	$l = 5$
Cenário 8	1	90	TL+TC	Cenário 8	$l = 18$
Cenário 9	1	50	TL+TC	Cenário 9	$l = 16$

6.2.6 Resultados de Previsão com Tráfego Real

A Figura 6.11 apresenta o resultado obtido considerando as métricas de Taxa de Aproveitamento de Oportunidades e Taxa de Colisão, para os preditores com HMM e com RF. Apresentamos os resultados obtidos ao aplicar o preditor com HMM e o preditor

com RF com as configurações selecionadas da Tabela 6.6. As Figura 6.11(a) e a Figura 6.11(b) apresentam a Taxa de Aproveitamento de Oportunidades e as Figura 6.11(c) e a Figura 6.11(d) apresentam a Taxa de Colisão. A Figura 6.11(a) e a Figura 6.11(c) mostram os resultados do preditor com HMM e do preditor com RF para os cenários 5 e 6. Ambos os preditores apresentam desempenhos similares, com o preditor com RF obtendo resultado de Taxa de Aproveitamento de Oportunidades (W) 0,30% e 0,45% maior que os preditores com HMM, nos cenários 5 e 6, respectivamente. Como o intervalo entre pacotes no cenário 6 é menor do que no cenário 5, podemos concluir que a ocupação do canal no cenário 6 é maior do que no cenário 5. Alinhado com as conclusões obtidas com tráfego sintético, o preditor com HMM apresentou uma redução do valor de W nos cenários com maior ocupação. Este mesmo comportamento é percebido nos resultados dos cenários avaliados da base DySPAN. A Taxa de Colisão permanece menor do que 0,3% em todos os casos avaliados, com pequena vantagem para o preditor com HMM.

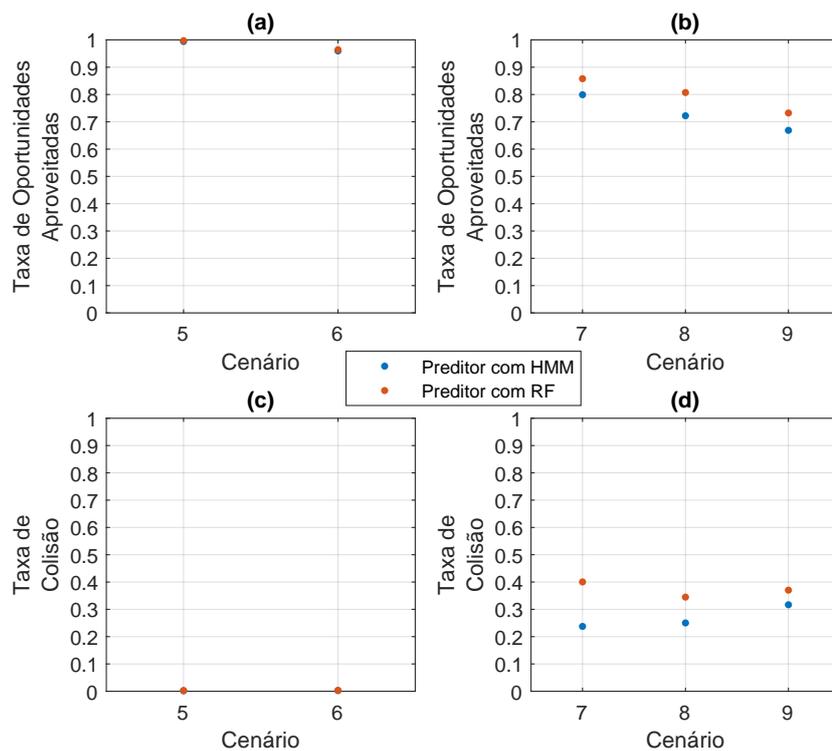


Figura 6.11: Taxa de oportunidades aproveitadas e taxa de colisão para os cenários 5-9.

A Figura 6.11(b) mostra a Taxa de Aproveitamento de Oportunidades (W) e a Figura 6.11(d) mostra a Taxa de Colisão (C) do preditor com HMM e do preditor com RF para os cenários 7, 8 e 9. Ao utilizar o preditor com HMM para os cenários em que o intervalo entre pacotes é determinado por distribuições de Poisson (7-9), percebemos que

a W é menor para os cenários com maior ocupação. A taxa de ocupação é 5,11%, 9,25% e 16,56% para os cenários 7, 8 e 9, respectivamente. Este comportamento é compatível com o comportamento obtido com tráfego sintético na Seção 5.3. Por outro lado, o preditor com RF obtém melhor resultado nos três casos em relação ao preditor com HMM, com aumento de W de 5%, 8% e 6% para os cenários 7, 8 e 9 respectivamente. O preditor com HMM obtém 16% menos colisão no cenário 7, 9% menos colisão no cenário 8 e 5% menos colisão no cenário 9, se comparado com os resultados do preditor com RF. Para o preditor com HMM, nos cenários 7 a 9, percebemos uma tendência de crescimento na taxa de colisão. Para os preditores com RF, percebemos uma tendência de estabilidade com os valores dessa métrica variando entre 35% e 40%. Neste ponto, vale ressaltar uma diferença do comportamento do PU nas transmissões coletadas nesta base em relação às transmissões sintéticas geradas. Na base DySPAN o tempo que o PU ocupa o canal em uma transmissão não segue uma distribuição de Poisson, mas varia uniformemente entre 1 e 2 *slots*. Recordando os valores da Tabela 5.7, para obter a taxa de ocupação do canal desejada foram ajustadas as médias de Poisson da duração das transmissões do PU. Portanto, a quantidade de *slots* ocupados cresce a medida que a ocupação do canal aumenta no tráfego sintético, ajudando a diluir a taxa de colisão percebida.

O gráfico da Figura 6.12 mostra o quantitativo de *slots* vagos presentes em cada um dos cenários da base DySPAN, e a classificação da previsão ao utilizar o preditor com HMM na configuração da Tabela 6.6. Adotaremos a classificação definida na Equação 4.2. A Figura 6.12(a) e a Figura 6.12(b) apresentam uma visão em proporção e a Figura 6.12(c) e a Figura 6.12(d) apresentam uma visão em números absolutos de *slots* vagos. Na Figura 6.12(c) e Figura 6.12(d) agrupamos de forma separada o quantitativo de *slots* vagos utilizados e *slots* vagos não utilizados. A quantidade de *slots* avaliados (soma dos ocupados e vagos) é igual em todos os cenários, definido pela quantidade de arquivos utilizados na etapa de teste. Portanto, temos $800 \times 64 = 51.200$ *slots* em cada cenário. Uma parte desses *slots* serão utilizados pelo PU e outra parte serão oportunidades disponíveis para a utilização pelo SU. Considere os quantitativos de *slots* vagos da Figura 6.12. Reforçando o que foi pontuado nos parágrafos anteriores, a Figura 6.12(a) e a Figura 6.12(c) mostram que grande parte dos *slots* utilizados são provenientes de previsões exatas nos cenários 5 e 6. Com pequena variabilidade na duração das ociosidades nestes cenários, o preditor foi capaz de se adequar aos dois cenários com o treinamento proposto. Na Figura 6.12(b) e na Figura 6.12(d), percebemos que a maior variabilidade resulta em menos previsões exatas e um quantitativo maior de previsões subestimadas. A quantidade de previsões exatas cresce do cenário 7 para o cenário 9, assim como a quantidade de *slots* vagos não utilizados. Há também uma redução na quantidade de *slots* vagos utilizados decorrentes de previsões subestimadas, reflexo da redução da duração média da ociosidade no canal

no cenário 9. Por consequência a quantidade de *slots* vagos não utilizados também cresce, indicando um distanciamento maior das previsões em relação ao tempo de ociosidade disponível.

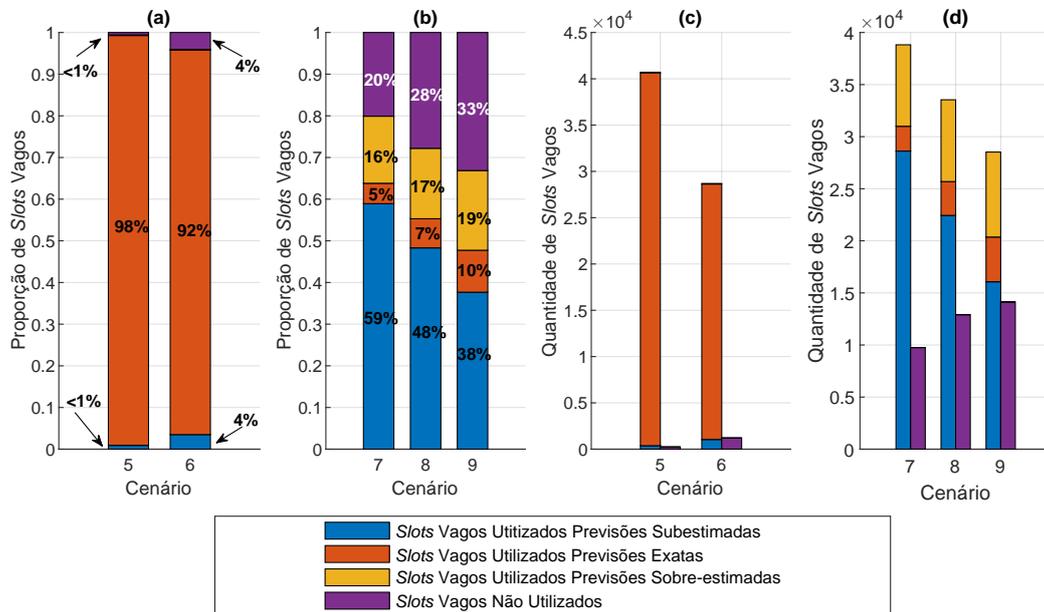


Figura 6.12: Quantidade de *slots* vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e a quantidade de *slots* não utilizados em cada cenário. (a-b) visão em proporção e (c-d) visão em números absolutos. Valores referentes ao emprego do preditor com HMM.

O gráfico da Figura 6.13 mostra o quantitativo de *slots* vagos presentes em cada um dos cenários da base DySPAN, e a classificação da previsão ao utilizar o preditor com RF na configuração da Tabela 6.6. A Figura 6.13(a) e a Figura 6.13(b) apresentam uma visão em proporção e a Figura 6.13(c) e a Figura 6.13(d) apresentam uma visão em números absolutos de *slots* vagos. Na Figura 6.13(c) e Figura 6.13(d) agrupamos de forma separada o quantitativo de *slots* vagos utilizados e *slots* vagos não utilizados. A Figura 6.13(a) e a Figura 6.13(c) mostram que a maioria das previsões do preditor com RF são previsões exatas, com grande similaridade com os resultados do preditor com HMM. Este resultado mostra a capacidade de adaptação do preditor com RF aos cenários 5 e 6. Para os cenários 7, 8 e 9 percebemos que o preditor com RF registra um quantitativo de *slots* utilizados provenientes de previsões sobre-estimadas maior do que o observado no preditor com HMM. No preditor com RF, 31% dos *slots* vagos são provenientes de previsões sobre-estimadas no cenário 7, 24% no cenário 8 e 21% no cenário 9. Para o preditor com HMM, esses *slots* representam aproximadamente 16% no cenário 7 e no cenário 8, e 19% no cenário 9. Com relação à quantidade de *slots* decorrentes previsões exatas, ambos os

preditores apresentam resultados similares, com diferença marginal menor ou igual a 1% do total de *slots* vagos para os cenários de 5 a 8. Para o cenário 9 essa diferença passa a ser aproximadamente 3%.

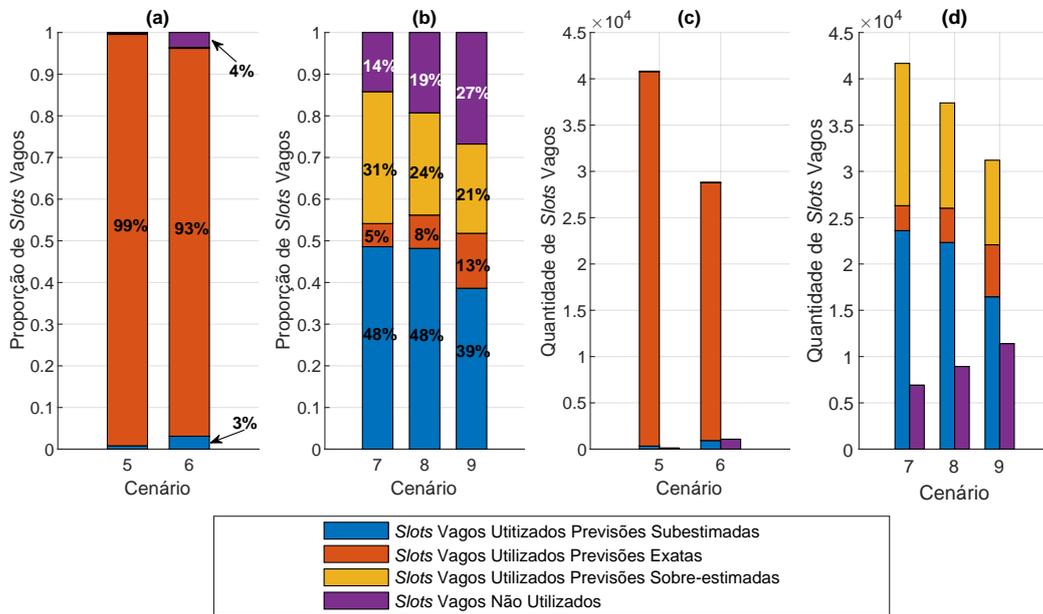


Figura 6.13: Quantidade de *slots* vagos utilizados por previsões subestimadas, previsões exatas e previsões sobre-estimadas, e a quantidade de *slots* não utilizados em cada cenário. (a-b) visão em proporção e (c-d) visão em números absolutos. Valores referentes ao emprego do preditor com RF.

Portanto, podemos perceber a partir dos resultados apresentados que ambos os preditores possuem comportamentos semelhantes nos cenários em que o comportamento do PU possui menor variabilidade. Nos cenários mais complexos o preditor com HMM se mostra superior ao preditor com RF no que tange a evitar colisão com o PU, reduzindo em média 10% a quantidade de colisão. Por outro lado, o preditor com RF se mostra mais eficiente em aproveitar as oportunidades disponíveis, obtendo em média 6,9% a mais de aproveitamento.

6.3 Discussão

Neste capítulo avaliamos o mecanismo de previsão com HMM proposto em uma base de coletas reais. Um preditor com RF também foi proposto para servir como critério de comparação para as previsões realizadas com o preditor com HMM. Os resultados mostraram que os preditores com HMM e com RF são capazes de se adaptar aos cenários a que foram expostos com um treinamento adequado. Adotando uma metodologia seme-

lhante à aplicada no Capítulo 5, vimos que nos cenários onde o comportamento do PU possui um comportamento periódico os preditores obtiveram ótimos resultados, causando poucas colisões e aproveitando quase que a totalidade das oportunidades disponíveis. Nos cenários em que o comportamento do PU possui maior variabilidade, o preditor com RF se mostrou mais efetivo no uso das oportunidade mas obteve maior taxa de colisão que o preditor com HMM com a aplicação dos aprimoramentos TL e TC.

A adoção dos valores adequados de α na métrica MAOD foram eficazes em evitar a escolha de configurações que resultassem em baixo aproveitamento das oportunidades. Uma investigação específica relacionada a configuração do preditor com RF se faz necessária, dado que apenas a implementação padrão encontrada no MATLAB foi avaliada.

Capítulo 7

Conclusões e Trabalhos Futuros

A partir dos dados obtidos através do sensoriamento do espectro é possível caracterizar o comportamento do PU na utilização do canal. Esses dados podem ser utilizados para treinar modelos de inteligência artificial para prever oportunidades de transmissão, viabilizando a aplicação do OSA. O aprendizado de máquina vem sendo aplicado com sucesso nas mais variadas áreas do conhecimento, e assim é também utilizado para previsão de espectro. O objetivo é capacitar os SUs para aprender os padrões de transmissões do PU de modo que os primeiros possam explorar os períodos ociosos do canal sem causar interferência prejudicial aos usuários licenciados.

O fruto inicial deste trabalho foi publicado em [106] e apresentou a utilização do preditor proposto por Saad *et al.* [23] no cenário em que o PU ocupada o canal por 50% do tempo e seu comportamento foi determinado por uma distribuição de Poisson. Nesse trabalho, mostramos que a aplicação do preditor neste cenário se mostrou pouco efetiva em evitar colisões. Para melhorar o desempenho do preditor, foi proposto um mecanismo de revisão das previsões realizadas, capaz de reduzir a taxa de colisão que inicialmente era da ordem de 50% para apenas 6%. Isso permitiu a validação do procedimento de previsão elaborado e a introdução de melhorias pós previsão que permitiram reduzir a taxa de colisão e aumentar o uso efetivo das oportunidades pelo SU.

Uma extensão deste trabalho foi recentemente aceita no CANDAR 2021 (*The Ninth International Symposium on Computing and Networking*), ainda não publicado “*On the Performance of Hidden Markov Model Spectrum Opportunity Forecast on Limited Observed Channel Activity*”. Nesse trabalho apresentamos uma avaliação do preditor utilizado em [106] onde o processo de treinamento dos preditores foi modificado com o objetivo de obter um conjunto de treinamento balanceado. Os preditores foram avaliados em canais onde o PU utiliza o canal entre 10% e 90% do tempo. Mostramos que com o novo treinamento é possível atingir 90% de aproveitamento das oportunidades com menos de 10% de colisão com PU. Em relação ao preditor padrão, sem as modificações no treinamento, a

redução média alcançada na taxa de colisão foi de aproximadamente 45%. Os resultados destas duas publicações estão consolidados no Capítulo 5 desta dissertação. Também estabelecemos um mecanismo efetivo de escolha da melhor configuração do preditor para cada cenário. Pelo fato de que o comportamento do PU ter sido gerado de forma sintética, não podemos afirmar, com estes resultados, que o preditor funcionaria em um cenário real. Para dirimir esta limitação, a aplicação do preditor em um cenário de tráfego real foi avaliada.

No Capítulo 6 estendemos a utilização do preditor baseado em HMM avaliado no Capítulo 5. Avaliamos o preditor elaborado em um cenário com tráfego real obtido a partir de uma base de dados pública de coletas, com o objetivo de avaliar a adaptação do preditor a outros comportamentos do PU. Neste escopo, um preditor baseado em floresta aleatória foi desenvolvido e adaptado para utilização no mesmo cenário, permitindo a avaliação e comparação de desempenho dos dois preditores. Os aprimoramentos propostos no treinamento do preditor com HMM foram avaliados e mostraram que são capazes de trazer melhora no desempenho do preditor no cenário avaliado, obtendo uma taxa de colisão melhor do que o preditor com floresta aleatória. Planejamos a submissão dos resultados apresentados nesse capítulo para um artigo de revista, a ser elaborado. Por questões de tempo e delimitação do escopo deste trabalho, deixamos como trabalho futuro a avaliação do impacto do conjunto de treinamento balanceado no preditor com floresta aleatória. Outro ponto que merece melhor atenção é o formato de escolha do conjunto balanceado de treinamento, já que neste trabalho nos limitamos a estratégia de escolha das primeiras ocorrências. Deste modo, é possível explorar a representatividade deste conjunto de treinamento com o objetivo de melhorar ainda mais o desempenho dos preditores. Outra delimitação importante nos resultados apresentados nesse capítulo é que os preditores elaborados foram aplicados para previsão de um único canal. Uma forma de explorar estes resultados é adaptar o procedimento de previsão para avaliar os quatro canais disponíveis na base de coletas utilizada.

A aplicação dos preditores nos cenários sintético e real permitiram uma avaliação teórica e prática do funcionamento dos preditores elaborados com base em duas técnicas de aprendizado de máquina. Os resultados mostraram a aplicação dos aprimoramentos propostos trazem benefício para o preditor com HMM, por conta do conjunto de treinamento balanceado. Os resultados obtidos mostram também que os aprimoramentos são efetivos em diversos cenários de ocupação do canal pelo PU. O desempenho do preditor com RF sugere que, nos cenários avaliados, ele é capaz de fazer com que o SU aproveite mais oportunidades do que o preditor com HMM. Porém o preditor com RF terá maior custo computacional, e portanto é necessário avaliar o custo benefício deste preditor para sua aplicação na previsão de espectro.

Referências

- [1] Höyhtyä, M., A. Mämmelä, M. Eskola, M. Matinmikko, J. Kalliovaara, J. Ojaniemi, J. Suutala, R. Ekman, R. Bacchus e D. Roberson: *Spectrum occupancy measurements: A survey and use of interference maps*. IEEE Communications Surveys Tutorials, 18(4):2386–2414, Fourthquarter 2016, ISSN 1553-877X. 1
- [2] Chen, Y. e H. Oh: *A survey of measurement-based spectrum occupancy modeling for cognitive radios*. IEEE Communications Surveys Tutorials, 18(1):848–859, Firstquarter 2016, ISSN 2373-745X. 1
- [3] Holland, O., H. Kokkinen, S. Wong, V. Friderikos, A. Raman, M. Dohler e M. Lema: *Changing availability of tv white space in the uk*. Electronics Letters, 52(15):1349–1351, 2016, ISSN 0013-5194. 1
- [4] Alwis, Chamitha De, Anshuman Kalla, Quoc Viet Pham, Pardeep Kumar, Kapal Dev, Won Joo Hwang e Madhusanka Liyanage: *Survey on 6g frontiers: Trends, applications, requirements, technologies and future research*. IEEE Open Journal of the Communications Society, 2:836–886, 2021. 1
- [5] ITU: *Network 2030: A Blueprint of Technology, Applications and Market Drivers Towards the Year 2030 and Beyond*. https://www.itu.int/en/ITU-T/focusgroups/net2030/Documents/White_Paper.pdf, 2019. [Online; acessado em 21/11/2021]. 1
- [6] Mitola, J. e G.Q. Maguire: *Cognitive radio: making software radios more personal*. IEEE Personal Communications, 6(4):13–18, 1999. 1
- [7] Song, M., C. Xin, Y. Zhao e X. Cheng: *Dynamic spectrum access: from cognitive radio to network radio*. IEEE Wireless Communications, 19(1):23–29, 2012. 1, 7
- [8] Yucek, T. e H. Arslan: *A survey of spectrum sensing algorithms for cognitive radio applications*. IEEE Communications Surveys Tutorials, 11(1):116–130, First 2009, ISSN 2373-745X. 2
- [9] Ding, G., Y. Jiao, J. Wang, Y. Zou, Q. Wu, Y. Yao e L. Hanzo: *Spectrum inference in cognitive radio networks: Algorithms and applications*. IEEE Communications Surveys Tutorials, 20(1):150–182, Firstquarter 2018, ISSN 2373-745X. 2, 9, 15, 16, 29
- [10] Eren, Berkay, Mehmet Ali Guvenc e Selcuk Mistikoglu: *Artificial intelligence applications for friction stir welding: A review*. Metals and Materials International, 27(2):193–219, 2021. 2

- [11] Li, Hong, Haiyang Yu, Nai Cao, He Tian e Shiqing Cheng: *Applications of artificial intelligence in oil and gas development*. Archives of Computational Methods in Engineering, 28(3):937–949, 2021. 2
- [12] Maassen, Oliver, Sebastian Fritsch, Julia Palm, Saskia Deffge, Julian Kunze, Gernot Marx, Morris Riedel, Andreas Schuppert e Johannes Bickenbach: *Future medical artificial intelligence application requirements and expectations of physicians in german university hospitals: Web-based survey*. Journal of medical Internet research, 23(3):e26646, 2021. 2
- [13] Yin, Jiamin, Kee Yuan Ngiam e Hock Hai Teo: *Role of artificial intelligence applications in real-life clinical practice: Systematic review*. Journal of medical Internet research, 23(4):e25759, 2021. 2
- [14] Wu, Yuzhu, Zhen Zhang, Gang Kou, Hengjie Zhang, Xiangrui Chao, Cong Cong Li, Yucheng Dong e Francisco Herrera: *Distributed linguistic representations in decision making: Taxonomy, key elements and applications, and challenges in data science and explainable artificial intelligence*. Information Fusion, 65:165–178, 2021. 2
- [15] Vrontis, Demetris, Michael Christofi, Vijay Pereira, Shlomo Tarba, Anna Makrides e Eleni Trichina: *Artificial intelligence, robotics, advanced technologies and human resource management: a systematic review*. The International Journal of Human Resource Management, páginas 1–30, 2021. 2
- [16] Shawel, Bethelhem S., Dereje H. Woldegebreal e Sofie Pollin: *Convolutional LSTM-based long-term spectrum prediction for dynamic spectrum access*. Em *European Signal Processing Conference*, volume 2019-Septe, 2019, ISBN 9789082797039. 2, 3, 29, 31, 32, 36, 37, 40
- [17] Ren, Xiangyu, Hamed Mosavat-Jahromi, Lin Cai e David Kidston: *Spatio-temporal Spectrum Load Prediction using Convolutional Neural Network and Bayesian Estimation*. Em *2020 IEEE Global Communications Conference, GLOBECOM 2020 - Proceedings*, volume 2020-Janua, páginas 1–6, dec 2020, ISBN 9781728182988. 2, 29, 32, 36, 40
- [18] Yang, Chao, Tao Peng, Peiliang Zuo e Xinyue Wang: *A spectrum prediction method for bursty frequency bands*. Em *2021 IEEE Wireless Communications and Networking Conference Workshops, WCNCW 2021*, páginas 1–5, mar 2021, ISBN 9781728195070. 2, 29, 32, 33, 40
- [19] Li, Haoyu, Xiaojin Ding, Yiguang Yang, Xiaogu Huang e Genxin Zhang: *Spectrum Occupancy Prediction for Internet of Things via Long Short-Term Memory*. Em *2019 IEEE International Conference on Consumer Electronics - Taiwan, ICCE-TW 2019*, páginas 1–2, may 2019, ISBN 9781728132792. 2, 30, 32, 33, 34
- [20] Sun, Jiachen, Jinlong Wang, Guoru Ding, Liang Shen, Jian Yang, Qihui Wu e Ling Yu: *Long-term spectrum state prediction: An image inference perspective*. IEEE Access, 6:43489–43498, 2018. 2, 3, 30, 34, 37

- [21] Elias, Felipe, Evelio Fernández e Vitalio Alfonso Reguera: *Multi-step-ahead spectrum prediction for cognitive radio in fading scenarios*. Journal of Microwaves, Optoelectronics and Electromagnetic Applications, 19:457–484, dezembro 2020. 3, 29, 30, 34, 37
- [22] Ge, Chao, Zheng Wang e Xiaofei Zhang: *Robust long-term spectrum prediction with missing values and sparse anomalies*. IEEE Access, 7:16655–16664, 2019. 3
- [23] Saad, Ahmad, Henning F. Schepker, Barbara Staehle e Rudi Knorr: *Whitespace prediction using hidden markov model based maximum likelihood classification*. Em *IEEE Vehicular Technology Conference*, volume 2019-April, 2019, ISBN 9781728112176. 3, 15, 20, 29, 30, 32, 33, 34, 37, 38, 39, 40, 41, 44, 68, 91
- [24] Akbar, I. A. e W. H. Tranter: *Dynamic spectrum allocation in cognitive radio using hidden markov models: Poisson distributed case*. Em *Proceedings 2007 IEEE SoutheastCon*, páginas 196–201, March 2007. 3, 58
- [25] de Figueiredo, F. A. P., X. Jiao, W. Liu, I. Jabandzic, S. Giannoulis e I. Moerman: *A framework for intelligent spectrum sharing*. Em *2018 IEEE 4th International Forum on Research and Technology for Society and Industry (RTSI)*, páginas 1–6, 2018. 6
- [26] Wei, Z., D. Yang e L. Sang: *Dynamic system level frequency spectrum allocation scheme based on cognitive radio technology*. China Communications, 11(7):84–91, 2014. 7
- [27] SSC: *General survey of radio frequency bands – 30 MHz to 3 GHz*. Relatório Técnico, Shared Spectrum Company, September 2010. 7
- [28] Čabrić, D., S. Mishra, D. Willkomm, R. Brodersen e A. Wolisz: *A cognitive radio approach for usage of virtual unlicensed spectrum*. IST Mobile Wireless Communications Summit, June 2005. 7
- [29] Commission, Federal Communications: *Docket no 03-222 notice of proposed rule making and order*. Docket NO 03-222, December 2003. 7
- [30] McHenry, M.: *Spectrum white space measurements*. Seminar, June 2003. 7
- [31] Akyildiz, Ian F., Won yeol Lee, Mehmet C. Vuran e Shantidev Mohanty: *A survey on spectrum management in cognitive radio networks*. IEEE Communications Magazine, 46(4):40–48, 2008. 8, 14
- [32] Ahmad, W. S. H. M. W., N. A. M. Radzi, F. S. Samidi, A. Ismail, F. Abdullah, M. Z. Jamaludin e M. N. Zakaria: *5g technology: Towards dynamic spectrum sharing using cognitive radio networks*. IEEE Access, 8:14460–14488, 2020. 8, 10
- [33] Sharmila, A. e P. Dananjayan: *Spectrum sharing techniques in cognitive radio networks – a survey*. Em *2019 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN)*, páginas 1–4, 2019. 8

- [34] Lehr, W. e J. Crowcroft: *Managing shared access to a spectrum commons*. Em *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005.*, páginas 420–444, Nov 2005. 8, 9
- [35] Hassan, M. R., G. C. Karmakar, J. Kamruzzaman e B. Srinivasan: *Exclusive use spectrum access trading models in cognitive radio networks: A survey*. *IEEE Communications Surveys Tutorials*, 19(4):2192–2231, 2017. 10
- [36] Le, L. B. e E. Hossain: *Resource allocation for spectrum underlay in cognitive radio networks*. *IEEE Transactions on Wireless Communications*, 7(12):5306–5315, December 2008, ISSN 1536-1276. 10
- [37] Kim, Dong In, Long Bao Le e E. Hossain: *Joint rate and power allocation for cognitive radios in dynamic spectrum access environment*. *IEEE Transactions on Wireless Communications*, 7(12):5517–5527, December 2008, ISSN 1536-1276. 10
- [38] Kaushik, A., S. K. Sharma, S. Chatzinotas, B. Ottersten e F. K. Jondral: *On the performance analysis of underlay cognitive radio systems: A deployment perspective*. *IEEE Transactions on Cognitive Communications and Networking*, 2(3):273–287, Sept 2016. 10
- [39] Yuan, X., X. Qin, F. Tian, B. Jalaian, Y. Shi, Y. T. Hou, W. Lou e W. Trappe: *An online admission control algorithm for dynamic traffic in underlay coexistence paradigm*. *IEEE Transactions on Cognitive Communications and Networking*, 2(4):411–426, Dec 2016. 10
- [40] Chistyakov, A.: *Collision avoidance spectrum sharing technique using gfdm for cognitive wireless ad-hoc networks*. Em *2015 IEEE East-West Design Test Symposium (EWDTS)*, páginas 1–4, Sept 2015. 10
- [41] Martyna, J.: *Green power control in underlaying cognitive radio networks*. Em *2016 8th IFIP International Conference on New Technologies, Mobility and Security (NTMS)*, páginas 1–5, Nov 2016. 10
- [42] Goldsmith, A., S. A. Jafar, I. Maric e S. Srinivasa: *Breaking spectrum gridlock with cognitive radios: An information theoretic perspective*. *Proceedings of the IEEE*, 97(5):894–914, May 2009, ISSN 0018-9219. 10
- [43] Pesce, M., M. Centenaro, L. Badia e M. Zorzi: *Impact of correlated primary transmissions on the design of a cognitive radio inference engine*. Em *2016 IEEE International Conference on Communications Workshops (ICC)*, páginas 689–693, May 2016. 10
- [44] Sami, M., N. K. Noordin e M. Khabazian: *A tdma-based cooperative mac protocol for cognitive networks with opportunistic energy harvesting*. *IEEE Communications Letters*, 20(4):808–811, April 2016, ISSN 1089-7798. 10
- [45] Tan, L. T. e L. B. Le: *Distributed mac protocol design for full-duplex cognitive radio networks*. Em *2015 IEEE Global Communications Conference (GLOBECOM)*, páginas 1–6, Dec 2015. 10

- [46] Mo, J., H. S. Wilson So e J. Walrand: *Comparison of multichannel mac protocols*. IEEE Transactions on Mobile Computing, 7(1):50–65, Jan 2008, ISSN 1536-1233. 10
- [47] IEEE: *Ieee standard for definitions and concepts for dynamic spectrum access: Terminology relating to emerging wireless networks, system functionality, and spectrum management*. IEEE Std 1900.1-2019 (Revision of IEEE Std 1900.1-2008), páginas 1–78, 2019. 11
- [48] Shent, B., L. Huang, C. Zhao, Z. Zhou e K. Kwak: *Energy detection based spectrum sensing for cognitive radios in noise of uncertain power*. Em *2008 International Symposium on Communications and Information Technologies*, páginas 628–633, 2008. 11
- [49] Bhargavi, D. e C. R. Murthy: *Performance comparison of energy, matched-filter and cyclostationarity-based spectrum sensing*. Em *2010 IEEE 11th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*, páginas 1–5, 2010. 11
- [50] Arjoune, Y., Z. E. Mrabet, H. E. Ghazi e A. Tamtaoui: *Spectrum sensing: Enhanced energy detection technique based on noise measurement*. Em *2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, páginas 828–834, 2018. 11, 12
- [51] Zeng, Y., Y. Liang e R. Zhang: *Blindly combined energy detection for spectrum sensing in cognitive radio*. IEEE Signal Processing Letters, 15:649–652, 2008. 11
- [52] Eslami, A. e S. Karamzadeh: *Performance analysis of double threshold energy detection-based spectrum sensing in low snrs over nakagami-m fading channels with noise uncertainty*. Em *2016 24th Signal Processing and Communication Application Conference (SIU)*, páginas 309–312, 2016. 11, 12
- [53] Bao, Z., B. Wu, P. Ho e X. Ling: *Adaptive threshold control for energy detection based spectrum sensing in cognitive radio networks*. Em *2011 IEEE Global Telecommunications Conference - GLOBECOM 2011*, páginas 1–5, 2011. 11
- [54] Alom, M. Z., T. K. Godder, M. N. Morshed e A. Maali: *Enhanced spectrum sensing based on energy detection in cognitive radio network using adaptive threshold*. Em *2017 International Conference on Networking, Systems and Security (NSysS)*, páginas 138–143, 2017. 11, 12
- [55] Ranjan, A., Anurag e B. Singh: *Design and analysis of spectrum sensing in cognitive radio based on energy detection*. Em *2016 International Conference on Signal and Information Processing (IConSIP)*, páginas 1–5, 2016. 11
- [56] Chenggang Jiang, Yuanyuan Li, Wenling Bai, Yu Yang e Jinling Hu: *Statistical matched filter based robust spectrum sensing in noise uncertainty environment*. Em *2012 IEEE 14th International Conference on Communication Technology*, páginas 1209–1213, 2012. 11

- [57] Zhang, X., R. Chai e F. Gao: *Matched filter based spectrum sensing and power level detection for cognitive radio network*. Em *2014 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, páginas 1267–1270, 2014. 11
- [58] Lv, Q. e F. Gao: *Matched filter based spectrum sensing and power level recognition with multiple antennas*. Em *2015 IEEE China Summit and International Conference on Signal and Information Processing (ChinaSIP)*, páginas 305–309, 2015. 11
- [59] Salahdine, F., H. E. Ghazi, N. Kaabouch e W. F. Fihri: *Matched filter detection with dynamic threshold for cognitive radio networks*. Em *2015 International Conference on Wireless Networks and Mobile Communications (WINCOM)*, páginas 1–6, 2015. 11
- [60] Sharma, S. K., T. E. Bógale, S. Chatzinotas, L. B. Le, X. Wang e B. Ottersten: *Improving robustness of cyclostationary detectors to cyclic frequency mismatch using slepian basis*. Em *2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, páginas 456–460, 2015. 11
- [61] Semba Yawada, P. e A. J. Wei: *Cyclostationary detection based on non-cooperative spectrum sensing in cognitive radio network*. Em *2016 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, páginas 184–187, 2016. 11
- [62] Subramaniam, S., H. Reyes e N. Kaabouch: *Spectrum occupancy measurement: An autocorrelation based scanning technique using usrp*. Em *2015 IEEE 16th Annual Wireless and Microwave Technology Conference (WAMICON)*, páginas 1–5, 2015. 11
- [63] Ilyas, I., S. Paul, A. Rahman e R. K. Kundu: *Comparative evaluation of cyclostationary detection based cognitive spectrum sensing*. Em *2016 IEEE 7th Annual Ubiquitous Computing, Electronics Mobile Communication Conference (UEMCON)*, páginas 1–7, 2016. 11
- [64] Cohen, D. e Y. C. Eldar: *Compressed cyclostationary detection for cognitive radio*. Em *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, páginas 3509–3513, 2017. 11
- [65] Sutton, P. D., K. E. Nolan e L. E. Doyle: *Cyclostationary signatures in practical cognitive radio applications*. *IEEE Journal on Selected Areas in Communications*, 26(1):13–24, 2008. 11
- [66] Palacios, P., A. Castro, C. Azurdia-Meza e C. Estevez: *Svd detection analysis in cognitive mobile radio networks*. Em *2017 Ninth International Conference on Ubiquitous and Future Networks (ICUFN)*, páginas 222–224, 2017. 11
- [67] Zeng, Y. e Y. Liang: *Covariance based signal detections for cognitive radio*. Em *2007 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, páginas 202–207, 2007. 11

- [68] Zayen, B., A. Hayar e K. Kansanen: *Blind spectrum sensing for cognitive radio based on signal space dimension estimation*. Em *2009 IEEE International Conference on Communications*, páginas 1–5, 2009. 11
- [69] Kumar, K. V. Seshu, Ramakrishnan Saravanan, Rajappa Muthaiah e Maik Tech: *Cognitive radio spectrum sensing algorithms based on eigenvalue and covariance methods*. 2013. 11
- [70] Zhang, Q. T.: *Advanced detection techniques for cognitive radio*. Em *2009 IEEE International Conference on Communications*, páginas 1–5, 2009. 11
- [71] Zeng, Y. e Y. Liang: *Spectrum-sensing algorithms for cognitive radio based on statistical covariances*. *IEEE Transactions on Vehicular Technology*, 58(4):1804–1815, 2009. 11
- [72] Chen, A., Z. Shi e J. Xiong: *Generalized real-valued weighted covariance-based detection methods for cognitive radio networks with correlated multiple antennas*. *IEEE Access*, 7:34373–34382, 2019. 11
- [73] Zeng, Y. e Y. . Liang: *Eigenvalue-based spectrum sensing algorithms for cognitive radio*. *IEEE Transactions on Communications*, 57(6):1784–1793, 2009. 11
- [74] Zeng, Y. e Y. Liang: *Maximum-minimum eigenvalue detection for cognitive radio*. Em *2007 IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications*, páginas 1–5, 2007. 11
- [75] Althaf, C. I. M. e S. C. Prema: *Covariance and eigenvalue based spectrum sensing using usrp in real environment*. Em *2018 10th International Conference on Communication Systems Networks (COMSNETS)*, páginas 414–417, 2018. 11
- [76] Haiyun Tang: *Some physical layer issues of wide-band cognitive radio systems*. Em *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005.*, páginas 151–159, 2005. 11
- [77] Javed, J. N., M. Khalil e A. Shabbir: *A survey on cognitive radio spectrum sensing: Classifications and performance comparison*. Em *2019 International Conference on Innovative Computing (ICIC)*, páginas 1–8, 2019. 12
- [78] Kim, K., Y. Xin e S. Rangarajan: *Energy detection based spectrum sensing for cognitive radio: An experimental study*. Em *2010 IEEE Global Telecommunications Conference GLOBECOM 2010*, páginas 1–5, Dec 2010. 13
- [79] Shi, Zhiyuan, Xueyuan Jiang e Lianfen Huang: *A prediction approach for mac layer sensing in cognitive radio networks*. páginas 317–320, janeiro 2008. 14
- [80] Chen, Mei, Michael G. Madden e Yan Liu: *Refined learning of hidden markov models with a modified baum-welch algorithm and informative components*. Em *2010 IEEE International Conference on Progress in Informatics and Computing*, volume 1, páginas 165–169, 2010. 15

- [81] Ali, Jehad, Rehanullah Khan, Nasir Ahmad e Imran Maqsood: *Random forests and decision trees*. International Journal of Computer Science Issues(IJCSI), 9, setembro 2012. 15, 48
- [82] Gagniuc, Paul: *Markov Chains: From Theory to Implementation and Experimentation*. maio 2017, ISBN 978-1-119-38755-8. 16
- [83] Baum, Leonard E. e Ted Petrie: *Statistical inference for probabilistic functions of finite state markov chains*. Ann. Math. Statist., 37(6):1554–1563, dezembro 1966. 16
- [84] Baum, Leonard E. e J. A. Eagon: *An inequality with applications to statistical estimation for probabilistic functions of markov processes and to a model for ecology*. Bull. Amer. Math. Soc., 73(3):360–363, maio 1967. 16
- [85] Baum, Leonard E. e George R. Sell: *Growth transformations for functions on manifolds*. Pacific J. Math., 27(2):211–227, 1968. 16
- [86] Baum, Leonard E., Ted Petrie, George Soules e Norman Weiss: *A maximization technique occurring in the statistical analysis of probabilistic functions of markov chains*. Ann. Math. Statist., 41(1):164–171, fevereiro 1970. 16
- [87] Baum, L. E.: *An inequality and associated maximization technique in statistical estimation for probabilistic functions of markov processes*. Inequalities, 3:1–8, 1972. 16
- [88] Rabiner, L. R.: *A tutorial on hidden markov models and selected applications in speech recognition*. Proceedings of the IEEE, 77(2):257–286, Feb 1989, ISSN 1558-2256. 16, 17, 20, 44
- [89] Mor, Bhavya, Sunita Garhwal e Ajay Kumar: *A systematic review of hidden markov models and their applications*. Archives of Computational Methods in Engineering, maio 2020. 16
- [90] Park, Chang Hyun, Sang Won Kim, Sun Min Lim e Myung Sun Song: *Hmm based channel status predictor for cognitive radio*. páginas 1 – 4, janeiro 2008. 20
- [91] Bishop, Christopher M.: *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, 2006, ISBN 0387310738. 22, 24
- [92] Kotu, Vijay e Bala Deshpande: *Chapter 2 - data science process*. Em Kotu, Vijay e Bala Deshpande (editores): *Data Science (Second Edition)*, páginas 19–37. Morgan Kaufmann, second edition edição, 2019, ISBN 978-0-12-814761-0. <https://www.sciencedirect.com/science/article/pii/B9780128147610000022>. 24
- [93] Louppe, Gilles: *Understanding random forests: From theory to practice*, 2015. 26
- [94] Al-Tahmeesschi, Ahmed, Kenta Umebayashi, Hiroki Iwata, Miguel Lopez-Benitez e Janne Lehtomaki: *Applying Deep Neural Networks for Duty Cycle Estimation*. Em *IEEE Wireless Communications and Networking Conference, WCNC*, volume 2020-May, páginas 1–7, may 2020, ISBN 9781728131061. 29, 32, 35, 40

- [95] Zuo, Pei Liang, Tao Peng, Xinyue Wang, Kangyong You, Hanbo Jing, Wenbin Guo e Wenbo Wang: *Spectrum Prediction for Frequency Bands with High Burstiness: Analysis and Method*. Em *IEEE Vehicular Technology Conference*, volume 2020-May, páginas 1–7, may 2020, ISBN 9781728152073. 30, 32, 33
- [96] Zhao, Yuwei, Shan Luo, Zekun Yuan e Rongping Lin: *A New Spectrum Prediction Method for UAV Communications*. Em *2019 IEEE 5th International Conference on Computer and Communications, ICC3 2019*, páginas 826–830, dec 2019, ISBN 9781728147437. 30, 32, 33
- [97] Aygul, Mehmet Ali, Mahmoud Nazzal, Ali Riza Ekti, Ali Gorcin, Daniel Benevides Da Costa, Hasan Fehmi Ates e Huseyin Arslan: *Spectrum Occupancy Prediction Exploiting Time and Frequency Correlations Through 2D-LSTM*. Em *IEEE Vehicular Technology Conference*, volume 2020-May, 2020, ISBN 9781728152073. 30, 32, 33
- [98] Min, Rui, Daiming Qu, Yang Cao e Guohui Zhong: *Interference avoidance based on multi-step-ahead prediction for cognitive radio*. Em *2008 11th IEEE Singapore International Conference on Communication Systems*, páginas 227–231, 2008. 30, 34, 37
- [99] Xing, Xiaoshuang, Tao Jing, Wei Cheng, Yan Huo e Xiuzhen Cheng: *Spectrum prediction in cognitive radio networks*. *IEEE Wireless Communications*, 20(2):90–96, 2013. 30
- [100] Shahid, Adnan, Saleem Aslam, Hyung Seok Kim e Kyung Geun Lee: *Csit: Channel state and idle time predictor using a neural network for cognitive lte-advanced network*. *EURASIP Journal on Wireless Communications and Networking*, 2013:203, dezembro 2013. 30, 34, 37
- [101] Tang, Z. L e S. M Li: *Deep recurrent neural network for multiple time slot frequency spectrum predictions of cognitive radio*. *KSII Transactions on Internet and Information Systems*, 11:3029–3045, junho 2017. 30, 34, 37
- [102] PPGCC/PUCRS: *Qualis 2021*. <https://ppgcc.github.io/discentesPPGCC/pt-BR/qualis/>, 2021. [Online; acessado em 14/09/2021]. 31
- [103] Baddour, Kareem E., Amir Ghasemi e Humphrey Rutagemwa: *Spectrum Occupancy Prediction for Land Mobile Radio Bands Using a Recommender System*. Em *IEEE Vehicular Technology Conference*, volume 2018-Augus, páginas 1–6, aug 2018, ISBN 9781538663585. 32, 35
- [104] Yang, Xinyue, Aijun Liu e Xiaohu Liang: *Spectrum Occupancy Prediction Based on LEO Satellite Mobile Communication Service*. Em *2020 IEEE 6th International Conference on Computer and Communications, ICC3 2020*, páginas 712–717, 2020, ISBN 9781728186351. 32, 34
- [105] Kyeremateng-Boateng, Hubert, Marvin Conn, Darsana Josyula e Manohar Mareboyana: *Prediction of radio frequency spectrum occupancy*. Em *Proceedings - 2020 IEEE 19th International Conference on Trust, Security and Privacy in*

- Computing and Communications, TrustCom 2020*, páginas 2028–2034, 2020, ISBN 9780738143804. 32, 33
- [106] Bezerra, Rodrigo F., Jacir L. Bordim, Marcus V. Lamar e Marcos F. Caetano: *Hidden markov model spectrum predictor for poisson distributed traffic*. Em *International Conference on Wireless and Mobile Computing, Networking and Communications*, volume 2020-Octob, 2020, ISBN 9781728197227. 32, 33, 91
- [107] Liu, Lei, Hamed Mosavat-Jahromi, Lin Cai e David Kidston: *Hierarchical agglomerative clustering and LSTM-based load prediction for dynamic spectrum allocation*. Em *2021 IEEE 18th Annual Consumer Communications and Networking Conference, CCNC 2021*, páginas 1–6, jan 2021, ISBN 9781728197944. 32, 36
- [108] Yaffee, R.A. e M. McGee: *An Introduction to Time Series Analysis and Forecasting: With Applications of SAS® and SPSS®*. Time Series. Elsevier Science, 2000, ISBN 9780127678702. <https://books.google.com.br/books?id=LSojZBiBZBgC>. 35, 36
- [109] Toma, Ogeen H. e Miguel López-Benítez: *Traffic learning: A deep learning approach for obtaining accurate statistical information of the channel traffic in spectrum sharing systems*. *IEEE Access*, 9:124324–124336, 2021. 36
- [110] Al-Tahmeesschi, Ahmed, Kenta Umebayashi, Hiroki Iwata, Janne Lehtomäki e Miguel López-Benítez: *Feature-based deep neural networks for short-term prediction of wifi channel occupancy rate*. *IEEE Access*, 9:85645–85660, 2021. 36
- [111] Sikiru, Ismaeel A., Nasir Faruk, Segun I. Popoola, Yusuf Imam-Fulani, Abdulkareem. A. Oloyede, Lukman A Olawoyin e Nazmat. T. Surajudeen-Bakinde: *Effects of detection threshold and frame size on duty cycle in gsm bands*. Em *2017 IEEE 3rd International Conference on Electro-Technology for National Development (NIGERCON)*, páginas 343–346, 2017. 36
- [112] Saad, A., B. Staehle e R. Knorr: *Spectrum prediction using hidden markov models for industrial cognitive radio*. Em *2016 IEEE 12th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, páginas 1–7, Oct 2016. 41
- [113] Li, Xiaolin, M. Parizeau e R. Plamondon: *Training hidden markov models with multiple observations-a combinatorial method*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(4):371–377, 2000. 44
- [114] Rabiner, L., L.R. Rabiner e B.H. Juang: *Fundamentals of Speech Recognition*. Prentice-Hall Signal Processing Series: Advanced monographs. PTR Prentice Hall, 1993, ISBN 9780130151575. 44
- [115] Elkarami, Bashier, Abed Alkhateeb e Luis Rueda: *Cost-sensitive classification on class-balanced ensembles for imbalanced non-coding rna data*. Em *2016 IEEE EMBS International Student Conference (ISC)*, páginas 1–4, 2016. 45, 47, 56

- [116] Guo, Hongyu e Herna L. Viktor: *Learning from imbalanced data sets with boosting and data generation: The databoost-im approach*. SIGKDD Explor. Newsl., 6(1):30–39, junho 2004, ISSN 1931-0145. <https://doi.org/10.1145/1007730.1007736>. 45
- [117] Wilson, D. e Tony Martinez: *Reduction techniques for instance-based learning algorithms*. Machine Learning, 38:257–286, janeiro 2000. 45
- [118] Garcia-Moral, Ana Isabel, Rubén Solera-Urena, Carmen Pelaez-Moreno e Fernando Diaz-de Maria: *Data balancing for efficient training of hybrid ann/hmm automatic speech recognition systems*. IEEE Transactions on Audio, Speech, and Language Processing, 19(3):468–481, 2011. 45, 46
- [119] Sun, Gang, Jianqiao Liu, Wei Mengxue, Wang Zhongxin, Zhao Jia e Guan Xiaowen: *An ensemble classification algorithm for imbalanced text data streams*. Em *2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, páginas 1073–1076, 2020. 46
- [120] Malik, Hassan H. e Vikas S. Bhardwaj: *Automatic training data cleaning for text classification*. Em *2011 IEEE 11th International Conference on Data Mining Workshops*, páginas 442–449, 2011. 46
- [121] Piza, Daniel Lachner, Andreas Schulze-Bonhage, Thomas Stieglitz, Julia Jacobs e Matthias Dümpelmann: *Depuration, augmentation and balancing of training data for supervised learning based detectors of eeg patterns*. Em *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*, páginas 497–500, 2017. 46
- [122] Chatziantoniou, Eleftherios: *Spectrum Sensing and Occupancy Prediction for Cognitive Machine-to-Machine Wireless Networks Spectrum Sensing and Occupancy Prediction for Cognitive Machine-to-Machine Wireless Networks*, 2014. <http://hdl.handle.net/10547/581884>. 53
- [123] Networks, IEEE Dynamic Spectrum Access: *DySPAN Spectrum Challenge*. <https://dyspan2017.ieee-dyspan.org/spectrum-challenge.html>, 2017. [Online; acessado em 29/09/2021]. 58, 72
- [124] Saad, A. e B. Staehle: *Towards a time-domain traffic model for adaptive industrial communication in ism bands*. Em *2016 Wireless Days (WD)*, páginas 1–6, March 2016. 64, 70
- [125] Alvarez, Pedro: *Dataset for context-aware cognitive radio using deep learning*, 2017. <https://doi.org/10.7910/DVN/EBLENC>. 72
- [126] Paisana, F., A. Selim, M. Kist, P. Alvarez, J. Tallon, C. Bluemm, A. Puschmann e L. DaSilva: *Context-aware cognitive radio using deep learning*. Em *2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, páginas 1–2, 2017. 72, 75

Anexo I

Valores de Referência para Escolha do Preditor

Este anexo propõe-se a apresentar os valores numéricos obtidos na avaliação conduzida na Seção 6.2.5, para decisão do melhor valor de α a ser utilizado. A avaliação realizada considera a aplicação dos preditores, nas suas diversas configurações, para realização de previsão no conjunto destinado à seleção do melhor preditor. Mais detalhes sobre o conjunto de treinamento e o conjunto de seleção do melhor preditor podem ser encontrados na Seção 6.2.5. Para esta metodologia de escolha do valor do parâmetro α , consideramos as métricas de desempenho definidas na Seção 4.4.2, a saber a Taxa de Aproveitamento de Oportunidades (W) e Taxa de Colisão (C). Empregamos também a utilização de um terceiro valor, que representa a relação entre o impacto causado ao PU, medido por C , e o benefício obtido pelo SU ao aproveitar as oportunidades de transmissão, medido por W . Esta relação está representada por $W - C$.

A Tabela I.1 apresenta a configuração selecionada para cada intervalo de valores de α para os preditores com HMM e a Tabela I.2 para os preditores com RF, nos cenários 5 e 6. Também são apresentados os valores de C , W e $W - C$ obtidos ao realizar previsões para o conjunto destinado à seleção do melhor preditor.

Tabela I.1: Melhor conjunto de parâmetros do Preditor com HMM para os Cenários 5 e 6.

HMM					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 5	$0 \leq \alpha \leq 1$	$l = 4, S = 10, \text{TL+TC}$	0	1	1
Cenário 6	$\alpha = 0$	$l = 9, S = 10, \text{TL+TC}$	0	0,9321	0,9321
Cenário 6	$0,0001 \leq \alpha \leq 0,0202$	$l = 12, S = 10, \text{TC}$	0	0,9326	0,9326
Cenário 6	$0,0203 \leq \alpha \leq 0,3661$	$l = 13, S = 10, \text{TC}$	0,0013	0,9977	0,9964
Cenário 6	$\alpha \geq 0,3662$	$l = 17, S = 10, \text{TC}$	0,0015	0,9980	0,9965

Tabela I.2: Melhor conjunto de parâmetros do do Preditor com RF para os Cenários 5 e 6.

RF					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 5	$\alpha < 10^{-4}$	$l = 2$	0	0	0
Cenário 5	$\alpha \geq 10^{-4}$	$l = 4$	0	1	1
Cenário 6	$\alpha \leq 0,0015$	$l = 2$	0	0	0
Cenário 6	$0,0016 \geq \alpha > 1$	$l = 8$	0,0015	0,9993	0,9968
Cenário 6	$\alpha = 1$	$l = 4$	0,0067	0,9993	0,9926

A configuração do preditor para cada intervalo de α no cenário 7 está apresentado na Tabela I.3 para o preditor com HMM. As configurações para o cenário 7 do preditor com RF estão apresentadas na Tabela I.4. As configurações para o preditor com HMM no cenário 8 estão apresentadas na Tabela I.5 e as do preditor com RF no cenário 8 estão apresentadas na Tabela I.6. Por fim, a Tabela I.7 apresenta as configurações do preditor com HMM no cenário 9 e a Tabela I.8 apresenta as configurações do preditor com RF no cenário 9.

Tabela I.3: Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 7.

HMM					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 7	$0 \leq \alpha < 0,0602$	$l = 1, S = 10, \text{TL}$	0,1243	0,3750	0,2507
Cenário 7	$0,0602 \leq \alpha < 0,1718$	$l = 1, S = 10, \text{TL+TC}$	0,1314	0,4866	0,3552
Cenário 7	$0,1718 \leq \alpha < 0,3569$	$l = 1, S = 20, \text{TL+TC}$	0,1400	0,5279	0,3879
Cenário 7	$0,3569 \leq \alpha < 0,6259$	$l = 1, S = 30, \text{TL+TC}$	0,1500	0,5470	0,3970
Cenário 7	$0,6259 \leq \alpha \leq 1$	$l = 1, S = 40, \text{TL+TC}$	0,2671	0,6160	0,3489

Tabela I.4: Melhor conjunto de parâmetros do Preditor com RF para o Cenário 7.

RF					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 7	$0 \leq \alpha < 0,1326$	$l = 9$	0,3928	0,8660	0,4732
Cenário 7	$0,1326 \leq \alpha < 0,7074$	$l = 5$	0,3939	0,8757	0,4818
Cenário 7	$0,7074 \leq \alpha < 0,8280$	$l = 19$	0,4809	0,9117	0,4308
Cenário 7	$0,8280 \leq \alpha < 0,8746$	$l = 15$	0,5554	0,9272	0,3718
Cenário 7	$0,8746 \leq \alpha \leq 1$	$l = 1$	0,6590	0,9420	0,2830

Tabela I.5: Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 8.

HMM					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 8	$0 \leq \alpha < 0,1442$	$l = 1, S = 10, TL+TC$	0,0337	0,3671	0,3334
Cenário 8	$0,1442 \leq \alpha < 0,7028$	$l = 1, S = 80, TL+TC$	0,0497	0,4620	0,4123
Cenário 8	$0,7028 \leq \alpha \leq 1$	$l = 1, S = 90, TL+TC$	0,2635	0,5525	0,2890

Tabela I.6: Melhor conjunto de parâmetros do Preditor com RF para o Cenário 8.

RF					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 8	$0 \leq \alpha < 0,9432$	$l = 18$	0,2975	0,8234	0,5259
Cenário 8	$0,9432 \leq \alpha \leq 1$	$l = 1$	0,4255	0,2975	0,4056

Tabela I.7: Melhor conjunto de parâmetros do Preditor com HMM para o Cenário 9.

HMM					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 9	$0 \leq \alpha < 0,0614$	$l = 1, S = 20, TL+TC$	0,0347	0,3526	0,3179
Cenário 9	$0,0614 \leq \alpha \leq 1$	$l = 1, S = 50, TL+TC$	0,2743	0,4809	0,2066

Tabela I.8: Melhor conjunto de parâmetros do Preditor com RF para o Cenário 9.

RF					
Cenário	Intervalo de α	Config.	C	W	W - C
Cenário 9	$0 \leq \alpha < 0,4780$	$l = 12$	0,3027	0,7284	0,4257
Cenário 9	$0,4780 \leq \alpha < 0,9577$	$l = 16$	0,3378	0,7667	0,4289
Cenário 9	$0,9577 \leq \alpha \leq 1$	$l = 5$	0,3884	0,7690	0,3806

Considerando, em cada um dos cenários, que a configuração que produziu o maior valor de $W - C$ é a mais adequada. Podemos concluir que ao escolher α no intervalo $0,4780 \geq \alpha \geq 0,6258$ a configuração escolhida é a que obtém o maior valor de $W - C$ em cada um dos cenários avaliados. Como qualquer valor no intervalo indicado geraria a escolha dos mesmos preditores, adotamos $\alpha = 0,5$ para as avaliações condizidas no Capítulo 6. Por semelhança, este mesmo valor foi adotado para as avaliações realizadas no Capítulo 5.