

Matheus Wanderley Romão

**INFERÊNCIA BAYESIANA NA  
DETECÇÃO DE POTENCIAIS  
EVOCADOS AUDITIVOS EM  
REGIME PERMANENTE**

Belo Horizonte - Minas Gerais

Maio, 2020

Matheus Wanderley Romão

**INFERÊNCIA BAYESIANA NA DETECÇÃO DE  
POTENCIAIS EVOCADOS AUDITIVOS EM  
REGIME PERMANENTE**

Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Doutor em Engenharia Elétrica.

Universidade Federal de Minas Gerais - UFMG

Programa de Pós-Graduação em Engenharia Elétrica - PPGEE

Orientador: Carlos Julio Tierra-Criollo

Belo Horizonte - Minas Gerais

Maio, 2020

R761i

Romão, Matheus Wanderley.

Inferência bayesiana na detecção de potenciais evocados auditivos em regime permanente [recurso eletrônico] / Matheus Wanderley Romão. - 2020.

1 recurso online (123 f. : il., color.) : pdf.

Orientador: Carlos Julio Tierra-Criollo.

Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 108-123.

Bibliografia: f. 99-107.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia elétrica - Teses. 2. Inferência bayesiana - Teses.  
3. Potenciais auditivos evocados - Teses. I. Tierra-Criollo, Carlos Júlio.  
II. Universidade Federal de Minas Gerais. Escola de Engenharia.  
III. Título.

CDU: 621.3(043)

**"Inferência Bayesiana Na Detecção de Potenciais Evocados  
Auditivos Em Regime Permanente"**

**Matheus Wanderley Romão**

Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Doutor em Engenharia Elétrica.

Aprovada em 15 de maio de 2020.

Por:



---

**Prof. Dr. Carlos Julio Tierra Criollo  
PEB (UFRJ) - Orientador**



---

**Prof. Dr. Leonardo Amáral Mozelli  
(UFMG)**



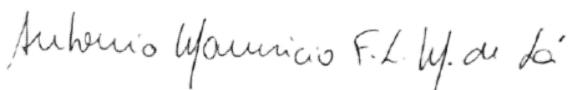
---

**Prof. Dr. Eduardo Mazzoni Andrade Marçal Mendes  
DELT (UFMG)**



---

**Prof. Dr. Otavio Gomes Lins  
Posneuro (UFPE)**



---

**Prof. Dr. Antonio Mauricio Ferreira Leite Miranda de Sá  
PEB (UFRJ)**

## AGRADECIMENTOS

Agradeço ao meu orientador, professor Carlos Julio, pelos ensinamentos transmitidos ao longo dos anos e por estar sempre disponível em ajudar no desenvolvimento deste projeto.

Aos meus colegas da UFSJ, pela concessão do afastamento para me dedicar à conclusão da pesquisa.

A todos os meus amigos, em especial ao André, à Clarice e ao Martim, pela amizade e suporte nos períodos em que passei no Rio de Janeiro.

À minha família, pelo apoio constante em todas as etapas da minha vida.

À Bela, por estar sempre ao meu lado, fazendo tudo ficar mais leve.

# Resumo

Os potenciais evocados auditivos em regime permanente (do inglês, *Auditory Steady-State Response* - ASSR) são utilizados na prática clínica audiológica para avaliar os limiares auditivos. Técnicas objetivas de detecção, no domínio da frequência, têm sido desenvolvidas para identificar o ASSR com base na abordagem clássica de Neyman-Pearson. Estes detectores são considerados ótimos para um dado nível de significância para aceitar ou rejeitar a hipótese nula  $H_0$  (ausência de resposta). Por outro lado, a abordagem bayesiana permite a inclusão de informações prévias (a priori) das hipóteses  $H_0$  e  $H_1$  (presença de resposta) no modelo e a atualização dessas informações com o conhecimento gerado a posteriori. Essa abordagem, no entanto, não foi explorada com relação às técnicas objetivas de detecção da ASSR, possibilitando a busca de novos paradigmas, que podem contribuir para esse campo de estudo, principalmente na redução do tempo necessário para a detecção de resposta. O objetivo deste trabalho é investigar a inferência bayesiana no desenvolvimento de detectores para melhor identificar os ASSR. Foram implementados os detectores com base no teste espectral F (SFT) e na magnitude quadrática da coerência (MSC), tanto para a abordagem clássica quanto para a bayesiana. Um levantamento teórico e simulações de Monte Carlo foram realizadas para avaliar o desempenho dos detectores em função da relação sinal/ruído (RSR). Para possibilitar a aplicação em dados reais, foi realizado também um estudo sobre a estimativa da RSR. Em seguida, os dois detectores foram aplicados a registros de ASSR de nove indivíduos com audição normal submetidos a tons modulados em amplitude de várias intensidades. Os resultados da simulação mostraram que o SFT e a MSC apresentaram desempenhos semelhantes. Entre os cenários analisados, o de melhor desempenho foi o detector bayesiano em que os menores valores possíveis para a probabilidade a priori foram atribuídos a  $H_0$ , permitindo a detecção para baixos valores de RSR. O pior desempenho do detector bayesiano ocorreu quando as probabilidades a priori de ambas as hipóteses foram iguais (atingindo a performance ideal em patamares semelhantes aos do detector Neyman-Pearson). Resultados similares foram encontrados nos dados de ASSR e também mostraram que estímulos de intensidade mais alta levaram a um melhor desempenho e uma detecção mais rápida devido ao incremento da RSR. Conclui-se que o detector bayesiano pode ser implementado de diversas maneiras, tendo em vista a liberdade de escolha para atribuição de custos às decisões que podem ser tomadas e para as probabilidades de ocorrência de cada uma das hipóteses concorrentes. Verificou-se que a estratégia de escolha das probabilidades a priori tem grande influência no desempenho que será alcançado pelo detector, o que em uma aplicação real pode contribuir na redução do tempo necessário para a tomada de uma decisão.

**Palavras-chave:** Inferência Bayesiana, Teste Espectral F, Magnitude Quadrática da Coerência, Detecção Objetiva de Respostas, Potenciais Evocados Auditivos.

# Abstract

Auditory steady-state responses (ASSR) are used in clinical practice to assess hearing thresholds. Objective response detection techniques, in the frequency domain, have been developed to identify the ASSR based on the classical Neyman-Pearson approach. These detectors are considered optimal for a given level of significance to either accept or reject the null hypothesis  $H_0$  (no response). On the other hand, the Bayesian approach allows the inclusion of prior information for  $H_0$  and  $H_1$  (response) hypotheses in the model and enables updating of this information with the posterior knowledge. This approach, however, has not been explored with respect to objective ASSR detection techniques. This enables the exploration of new paradigms, which may contribute to this field of study, especially in terms of the time required for response detection. The aim of this work is to investigate the bayesian approach in the development of detectors to better identify the ASSR. Detection algorithms for these potentials were implemented based on the Spectral F test (SFT) and the magnitude squared coherence (MSC), both for the classical and bayesian approaches. Theoretical assessment and Monte Carlo simulations were performed to evaluate the performances of both detectors as a function of the signal-to-noise ratio (SNR). To enable the application in ASSR data, a study was carried out on the SNR estimation. Then, the two detectors were applied to ASSR recordings of nine normal-hearing subjects stimulated by amplitude-modulated tones of various intensities. Simulation results showed that the SFT and the MSC performed similarly. Among the scenarios analyzed, the most promising case was the bayesian approach in which the lowest possible values for the a priori probability was selected for the  $H_0$ , allowing detection at low SNR levels. The bayesian detector worst performance occurred when the a priori probabilities for both hypotheses were equal (reaching ideal performance at SNR levels similar to the Neyman-Pearson detector). Similar results were found in the ASSR data and also showed that higher stimulus intensity led to better performance and faster detection due to improvements in the SNR. It is concluded that the Bayesian detector can be implemented in many ways, given the possibility of arbitrary choices for assigning costs to the decisions that can be made and for the probabilities of occurrence of each of the competing hypotheses. It was found that the strategy of choosing the a priori probabilities has a great influence on the performance that will be achieved by the detector, which in a real application can contribute to reducing the time needed to make a decision.

**Keywords:** Bayesian Inference, Spectral F-Test, Magnitude Squared Coherence, Objective Response Detection, Auditory Evoked Potentials.

# Lista de Ilustrações

Figura 1 – Objetivos específicos . . . . .	17
Figura 2 – Efeito da estimulação por tons AM nas estruturas do sistema auditivo .	22
Figura 3 – Erros tipo I e II e Poder do teste. . . . .	44
Figura 4 – Detector de máxima verossimilhança. . . . .	46
Figura 5 – Curva ROC e limiar de decisão. . . . .	48
Figura 6 – Curvas ROC do detector NP para SFT ( $M=4$ ; $M=12$ ; $M=16$ ) . . . . .	58
Figura 7 – Curvas ROC do detector NP para SFT ( $M=32$ ; $M=48$ ; $M=64$ ; $M=96$ )	59
Figura 8 – Curvas PD do detector NP aplicado ao SFT . . . . .	60
Figura 9 – Desempenho do detector NP em função da RSR para SFT . . . . .	61
Figura 10 – Desempenho do detector bayesiano para SFT ( $M = 4$ ) . . . . .	62
Figura 11 – Desempenho do detector bayesiano para SFT ( $M = 12$ e $M = 16$ ) . . .	63
Figura 12 – Desempenho do detector bayesiano para SFT ( $M = 32$ e $M = 48$ ) . . .	63
Figura 13 – Desempenho do detector bayesiano para SFT ( $M = 64$ e $M = 96$ ) . . .	64
Figura 14 – Detector bayesiano para SFT ( $M=16$ ) . . . . .	66
Figura 15 – Curvas ROC do detector NP para MSC ( $N=4$ ; $N=12$ e $N=16$ ) . . . . .	67
Figura 16 – Curvas ROC do detector NP para MSC ( $N=32$ ; $N=48$ ; $N=64$ e $N=96$ )	68
Figura 17 – Curvas PD do detector NP aplicado à MSC em função da RSR . . . . .	69
Figura 18 – Desempenho do detector bayesiano (PE) para MSC ( $N=4$ ) . . . . .	70
Figura 19 – Desempenho do detector bayesiano (PE) para MSC ( $N=12$ e $N=16$ ) .	70
Figura 20 – Desempenho do detector bayesiano (PE) para MSC ( $N=32$ e $N=48$ ) .	71
Figura 21 – Desempenho do detector bayesiano (PE) para MSC ( $N=64$ e $N=96$ ) .	71
Figura 22 – Detector bayesiano para MSC ( $N=16$ ) . . . . .	72
Figura 23 – Relação entre a curva ROC e a performance do detector bayesiano . . .	74
Figura 24 – Sobreposição das curvas de desempenho do detectores NP e bayesiano .	76
Figura 25 – Comparação de desempenho das curvas ROC de MSC em relação ao SFT	77
Figura 26 – Performances dos estimadores (MAP) aplicados ao SFT quando RSR=1	78
Figura 27 – Performances dos estimadores (MAP) aplicados ao SFT quando RSR=0	80
Figura 28 – Performances dos estimadores (MAP) aplicados à MSC quando RSR=1	81
Figura 29 – Performances dos estimadores (MAP) aplicados à MSC quando RSR=0	82
Figura 30 – Performances dos estimadores com melhor desempenho para SFT e MSC	83
Figura 31 – Desempenho dos detectores NP e bayesiano em registros ASSR para SFT	85



Figura 32 – Desempenho dos detectores NP e bayesiano em registros ASSR para MSC	87
Figura 33 – Sobreposição das curvas de desempenho quando há respostas . . . . .	88
Figura 34 – Sobreposição das curvas de desempenho quando não há respostas . . . . .	89
Figura 35 – Valores críticos do detector bayesiano para SFT ( $M=4$ ) . . . . .	116
Figura 36 – Valores críticos do detector bayesiano para SFT ( $M=12$ ) . . . . .	116
Figura 37 – Valores críticos do detector bayesiano para SFT ( $M=16$ ) . . . . .	117
Figura 38 – Valores críticos do detector bayesiano para SFT ( $M=32$ ) . . . . .	117
Figura 39 – Valores críticos do detector bayesiano para SFT ( $M=48$ ) . . . . .	118
Figura 40 – Valores críticos do detector bayesiano para SFT ( $M=64$ ) . . . . .	118
Figura 41 – Valores críticos do detector bayesiano para SFT ( $M=96$ ) . . . . .	119
Figura 42 – Valores críticos do detector bayesiano para MSC ( $N=4$ ) . . . . .	120
Figura 43 – Valores críticos do detector bayesiano para MSC ( $N=12$ ) . . . . .	121
Figura 44 – Valores críticos do detector bayesiano para MSC ( $N=16$ ) . . . . .	121
Figura 45 – Valores críticos do detector bayesiano para MSC ( $N=32$ ) . . . . .	122
Figura 46 – Valores críticos do detector bayesiano para MSC ( $N=48$ ) . . . . .	122
Figura 47 – Valores críticos do detector bayesiano para MSC ( $N=64$ ) . . . . .	123
Figura 48 – Valores críticos do detector bayesiano para MSC ( $N=96$ ) . . . . .	123

# Lista de Tabelas

Tabela 1 – Probabilidades a priori [ $P(RSR)$ ] utilizadas nas simulações dos estimadores bayesianos para os cenários com e sem respostas. . . . .	52
Tabela 2 – Desempenho (em %) dos detectores NP (PD) e bayesiano (PA) de todos os indivíduos e para todas as intensidades, referente ao SFT. “ $PA_{P(H0) \min}$ ” e “ $PA_{P(H0)=0,5}$ ” representam as performances do detector bayesiano para as estratégias “ $P(H0) \min$ ” e “ $P(H0) = 0,5$ ”, respectivamente. . . . .	90
Tabela 3 – Desempenho (em %) dos detectores NP (PD) e bayesiano (PA) de todos os indivíduos e para todas as intensidades, referente à MSC. “ $PA_{P(H0) \min}$ ” e “ $PA_{P(H0)=0,5}$ ” representam as performances do detector bayesiano para as estratégias “ $P(H0) \min$ ” e “ $P(H0) = 0,5$ ”, respectivamente. . . . .	90

## LISTA DE ABREVIATURAS E SIGLAS

ABC	<i>Approximate Bayesian Computation</i>
AM	Amplitude Modulada
ABR	<i>Auditory Brainstem Response</i>
ANOVA	<i>Analysis of Variance</i>
ASSR	<i>Auditory Steady-State Response</i>
CCE	Célula Ciliadas Externas
CCI	Células Ciliadas Internas
CSM	<i>Component Synchrony Measure</i>
dB <sub>SPL</sub>	<i>Decibel Sound Pressure Level</i>
EEG	Eletroencefalografia
FFT	<i>Fast Fourier Transform</i>
FM	Frequência Modulada
fdp	função densidade de probabilidade
IAFM	<i>Independent Amplitude and Frequency Modulation</i>
ICM	Interface Cérebro-Máquina
MAP	<i>Maximum a Posteriori</i>
MASTER	<i>Multiple Auditory Steady-State Responses</i>
MCMC	<i>Monte Carlo Markov Chain</i>
MEG	Magnetoencefalografia
MLE	<i>Maximum Likelihood Estimation</i>
MM	Modulação Mista

MMSE	<i>Minimum Mean Square Error</i>
MSC	<i>Magnitude Squared Coherence</i>
NP	Neyman-Pearson
ORD	<i>Objective Response Detection</i>
PA	Probabilidade de Acerto
PD	Probabilidade de Detecção
PE	Probabilidade de Erro
PEA	Potencial Evocado Auditivo
PEATE	Potencial Evocado Auditivo do Tronco Encefálico
PFA	Probabilidade de Falso Alarme
PM	<i>Probability of Miss-detection</i> (taxa de perda)
PMC	<i>Population Monte Carlo</i>
PRC	<i>Partial Rejection Control</i>
PSM	<i>Phase Synchrony Measure</i>
ROC	<i>Receiver Operating Characteristics</i>
RSR	Relação Sinal Ruído
SFT	<i>Spectral F Test</i>
SMC	<i>Sequential Monte Carlo</i>
TTI	Taxa de Transferência de Informação

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	Objetivos	16
1.2	Estrutura do Trabalho	17
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>19</b>
2.1	Potenciais Evocados Auditivos	19
2.1.1	Potenciais evocados auditivos transitórios	20
2.1.2	Potenciais evocados auditivos em regime permanente	21
2.1.2.1	Teste Espectral F (SFT)	28
2.1.2.2	Magnitude Quadrática da Coerência (MSC)	29
2.2	Inferência Bayesiana	31
2.2.1	Distribuições a priori	33
2.2.1.1	Abordagem Objetiva	33
2.2.1.1.1	O princípio da razão insuficiente	34
2.2.1.1.2	Método de Jeffreys	34
2.2.1.1.3	Método de Bernardo e Berger	34
2.2.1.1.4	Máxima entropia	35
2.2.1.1.5	Outras abordagens objetivas	37
2.2.1.2	Abordagem Subjetiva	37
2.2.1.2.1	Aproximação por meio de distribuições conhecidas	37
2.2.1.2.2	Abordagens não paramétricas	38
2.2.2	Estimação das distribuições a posteriori	38
2.2.3	Estimação paramétrica a partir da posteriori	40
2.3	Teste de Hipóteses	41
2.3.1	Abordagem Clássica	42
2.3.2	Abordagem Bayesiana	44
2.3.2.1	Detector bayesiano composto	46
2.3.3	Desempenho dos detectores	47
2.3.3.1	Critério Minimax	47
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>49</b>
3.1	Desempenho dos detectores	49
3.1.1	Desempenho teórico	49
3.1.1.1	Detector NP	50
3.1.1.2	Detector Bayesiano	50
3.1.2	Desempenho por simulações	50
3.2	Estimação da RSR	52
3.2.1	Estimação Bayesiana	52

3.2.2	Estimação Analítica . . . . .	53
3.3	Aplicação em dados reais . . . . .	54
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>57</b>
4.1	Desempenho dos detectores . . . . .	57
4.1.1	Teste SFT . . . . .	57
4.1.1.1	Detector NP . . . . .	57
4.1.1.2	Detector Bayesiano . . . . .	61
4.1.2	Desempenho para MSC . . . . .	67
4.1.2.1	Detector NP . . . . .	67
4.1.2.2	Detector Bayesiano . . . . .	69
4.1.3	Paralelo entre os detectores NP e Bayesiano . . . . .	73
4.1.3.1	Curva ROC vs. Mapas de contorno de PE . . . . .	73
4.1.3.2	Relação entre PD e PE . . . . .	75
4.1.4	Relação entre MSC e SFT . . . . .	76
4.2	Estimadores . . . . .	78
4.2.1	Aplicação para SFT . . . . .	78
4.2.2	Aplicação para MSC . . . . .	81
4.2.3	Definição dos estimadores para aplicação nos registros ASSR . . . . .	83
4.3	Aplicação em registros ASSR . . . . .	84
<b>5</b>	<b>DISCUSSÃO . . . . .</b>	<b>92</b>
<b>6</b>	<b>CONCLUSÃO . . . . .</b>	<b>97</b>
<b>REFERÊNCIAS . . . . .</b>		<b>99</b>
<b>APÊNDICE A - O SISTEMA AUDITIVO . . . . .</b>		<b>108</b>
<b>APÊNDICE B - LIMIARES DETECTOR BAYESIANO PARA SFT . . . . .</b>		<b>115</b>
<b>APÊNDICE C - LIMIARES DETECTOR BAYESIANO PARA MSC . . . . .</b>		<b>120</b>

# 1 INTRODUÇÃO

A neuroengenharia, uma especialidade da engenharia biomédica, visa a compreender como o sistema nervoso codifica e processa os diversos tipos de informações que viabilizam a interação do ser humano com o ambiente ao seu redor (DURAND, 2006; ELIASMITH; ANDERSON, 2004).

À medida que essa compreensão avança, vislumbram-se oportunidades de aplicação desses conhecimentos nas mais diversas áreas. Uma delas tem o objetivo de aprimorar os métodos e os equipamentos destinados ao diagnóstico e ao tratamento de doenças do sistema nervoso.

É o que ocorre, por exemplo, no campo de estudos acerca das modalidades sensoriais, no qual se busca compreender como o sistema nervoso reage quando os diferentes órgãos dos sentidos são estimulados. As investigações vão desde a conversão destes estímulos nos receptores sensoriais até a chegada dos sinais neurais no córtex cerebral. Apesar das diferenças anatômicas e fisiológicas existentes entre os cinco sentidos humanos, esse campo de estudo tem como premissa básica a necessidade de captação e o processamento dos sinais biológicos que se manifestam no sistema nervoso em resposta à estimulação sensorial.

Uma técnica muito difundida para o estudo das respostas cerebrais aos estímulos sensoriais é a Eletroencefalografia (EEG), que utiliza eletrodos posicionados no couro cabeludo para medir as variações dos potenciais elétricos resultantes da atividade de agrupamentos de neurônios localizados nas estruturas que constituem o encéfalo. As grandes vantagens da EEG estão no baixo custo de implementação e uso, na boa resolução temporal, na sua portabilidade e no fato de ser um método não invasivo de medição de sinais biológicos. Por outro lado, a EEG possui uma baixa resolução espacial e, principalmente, uma relação sinal/ruído (RSR) muito baixa, o que demanda o uso de técnicas de processamento de sinais para extração das informações de interesse (SCHOMER; SILVA, 2010).

Na literatura são descritos vários métodos de análise nos domínios do tempo, frequência e tempo-frequência. A escolha da técnica mais apropriada depende de aspectos específicos do estudo, como, por exemplo, o tipo de informação que se pretende extrair do Eletroencefalograma (SANEI; CHAMBERS, 2007; MUNNEKE et al., 2015; BONITA et al., 2014). Além disso, outro fator determinante nesta escolha é a restrição de tempo imposta pelas aplicações que, muitas vezes, exigem que o processamento do sinal de EEG

seja realizado no menor intervalo possível, como é o caso de interfaces cérebro-máquina, de aparelhos de monitoramento cirúrgico e de equipamentos de triagem de doenças (BAHMER; BAUMANN, 2010; CAVALCANTI et al., 2014).

Um contexto, no qual se observam tais restrições, envolve os potenciais evocados auditivos, que são alterações observadas na atividade elétrica cerebral desencadeadas por estímulos sonoros (PICTON et al., 2003). Muitos esforços têm sido feitos visando ao uso desses potenciais na rotina audiológica (LINS et al., 1996; HERDMAN; STAPELLS, 2001; ROMÃO, 2009; SOUZA, 2011; ZANOTELLI, 2011; ABDO, 2012; REZENDE, 2015; SANTOS et al., 2016), tendo como uma das principais motivações a possibilidade de estimação de limiares auditivos de forma objetiva, principalmente em recém-nascidos, para os quais uma detecção precoce de deficiências pode evitar o comprometimento no desenvolvimento da linguagem e da fala (LINS et al., 1996; RICKARDS et al., 1994). Contudo, o tempo necessário para o levantamento de um audiograma por meio destes potenciais ainda é um empecilho à sua aplicação prática e isso se deve, em grande parte, à dificuldade na detecção de respostas evocadas em decorrência dos elevados níveis de ruído presentes nos registros de EEG (VAN DER REIJDEN; MENS; SNIK, 2004; SININGER et al., 2018).

No campo de estudos dos potenciais evocados auditivos em regime permanente, o procedimento utilizado na análise desses sinais envolve a aplicação de métodos estatísticos de detecção no domínio da frequência, baseados no teste de hipóteses, cuja formulação pode seguir duas abordagens principais: a clássica, também conhecida como Neyman e Pearson (NP) e a Bayesiana (BARNETT, 1999).

Na identificação da resposta auditiva em regime permanente (ASSR - *Auditory Steady-State Response*), tem-se utilizado a abordagem clássica, que busca a maximização da probabilidade de detecção da resposta cerebral eliciada pelo estímulo sonoro a partir de uma restrição de erro tipo I (falsos positivos – decidir pela presença de resposta, quando, de fato, não há respostas) (LEVY, 2008). Embora seja amplamente empregado, o modelo de NP não leva em consideração qualquer conhecimento prévio que se tenha a respeito da probabilidade de ocorrência de cada uma das hipóteses consideradas. Além disso, a estruturação do modelo de NP é fundamentada na inferência frequentista e, desta forma, os erros associados às possíveis decisões são uma medida a longo prazo, que refletem o comportamento do fenômeno analisado após um elevado número de realizações do experimento.

A formulação Bayesiana, por outro lado, possibilita incorporar ao modelo a incerteza associada à ocorrência das hipóteses concorrentes, quantificando-a na forma de probabilidades a priori. Além disso, o paradigma bayesiano permite atribuir custos para cada tipo de decisão que pode ser tomada (KAY, 1998). Assim, tanto as informações relacionadas ao indivíduo avaliado (p.ex., estado de saúde, idade, histórico clínico) quanto



ao protocolo de estimulação (p.ex., intensidade, forma de onda, frequências de estimulação) poderiam ser utilizadas na construção do detector e com isso proporcionar melhores desempenhos na identificação de respostas evocadas.

Na literatura percebe-se o interesse em aprimorar o desempenho de detectores no domínio da frequência por meio da avaliação de diferentes métodos estatísticos, como, por exemplo, o teste espectral F (do inglês, *Spectral F-Test* - SFT) e a Magnitude Quadrática da Coerência (do inglês, *Magnitude Squared Coherence* - MSC). Contudo, os detectores implementados a partir desses métodos têm utilizado a abordagem de NP. Constata-se, portanto, que esses mesmos métodos de detecção não têm sido avaliados sob a ótica bayesiana, o que deixa em aberto oportunidades de exploração dessa temática.

Um grande desafio se revela, então, na maneira como representar as informações prévias na forma de distribuições de probabilidade, para aplicação bayesiana. Outra questão que emerge diz respeito a como estas informações afetarão o desempenho dos detectores, sobretudo no tempo necessário para a detecção dos potenciais evocados auditivos.

Este trabalho, portanto, vislumbra três contribuições no campo de estudos dos potenciais evocados auditivos, sendo a primeira delas, a implementação de detectores para esses sinais segundo a abordagem bayesiana. Já a segunda, busca a estimação da RSR por meio de técnicas bayesianas e não bayesianas; a terceira, por sua vez, visa a validação dos detectores bayesianos por meio da sua aplicação em registros ASSR. Desta forma, espera-se que esse trabalho colabore para que o uso da inferência bayesiana seja melhor explorada nesse contexto, visando ao aprimoramento dos métodos de detecção de resposta cerebral a estímulos sensoriais.

## 1.1 OBJETIVOS

O objetivo principal deste trabalho é utilizar a inferência bayesiana no desenvolvimento de detectores para as técnicas SFT e MSC, visando a aplicações em potenciais evocados auditivos em regime permanente.

Para isso, são elencados os seguintes objetivos específicos (Figura 1):

- Implementar os testes de hipóteses dos detectores NP e bayesiano e avaliar o desempenho dos detectores utilizando simulações de Monte Carlo;
- Utilizar técnicas bayesianas e não bayesianas para a estimação da RSR;
- Aplicar os detectores e os estimadores em registros ASSR para validação experimental.

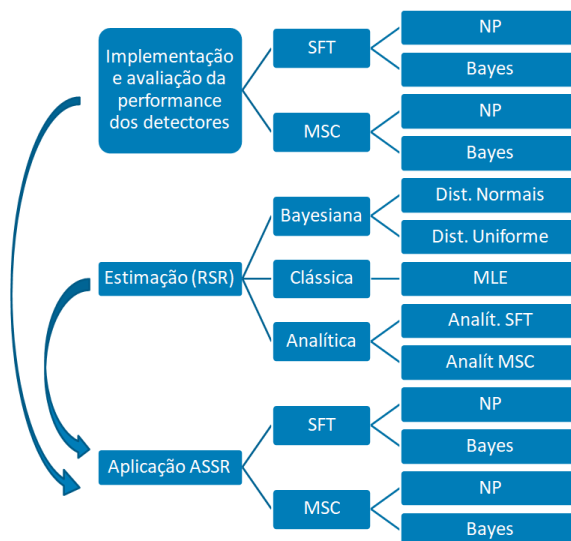


Figura 1 – Objetivos específicos. O primeiro objetivo visa implementar e avaliar a performance dos detectores para SFT e MSC, sob as abordagens Neyman-Pearson (NP) e de Bayes. O segundo objetivo visa a estimação da RSR sob três abordagens: Bayesiana (com probabilidades a priori Normais e Uniforme), Clássica (por meio do estimador de máxima verossimilhança - MLE) e por meio de expressões analíticas baseadas nas amostras de SFT (Analít. SFT) e MSC (Analít. MSC). O terceiro objetivo visa a aplicação dos detectores e estimadores em registros ASSR, para as duas técnicas (SFT e MSC) e em relação as duas abordagens (NP e Bayes).

Fonte: Dados da pesquisa.

## 1.2 ESTRUTURA DO TRABALHO

O presente trabalho está estruturado em seis capítulos, incluindo a parte introdutória, já apresentada. O capítulo 2 traz uma breve revisão acerca dos assuntos relacionados às áreas do conhecimento nas quais esse projeto se insere e os conceitos teóricos envolvidos no desenvolvimento da parte experimental. Dada a diversidade dos conteúdos abordados, este capítulo foi organizado em seções temáticas. Desta forma, a primeira seção versa sobre os potenciais evocados auditivos<sup>1</sup> transitórios e em regime permanente. Por ser uma das temáticas centrais deste trabalho, este último é tratado com um grau de detalhamento maior, sendo apresentadas, em um primeiro momento, as suas principais características. Em seguida é feita uma revisão da literatura que descreve as estratégias utilizadas para reduzir o tempo necessário para o levantamento das respostas evocadas em regime permanente. São apresentadas também algumas aplicações destas respostas e as principais técnicas estatísticas utilizadas no seu processamento. A segunda seção trata da inferência bayesiana, que é a abordagem sobre a qual este projeto se desenvolve. Nesta seção é apresentado o teorema de Bayes e os principais métodos utilizados para a estimação das distribuições de probabilidade envolvidas em sua formulação. Por fim, a terceira seção dedica-se ao teste de hipótese e visa a explicitar os dois paradigmas que podem ser utilizados na detecção de

<sup>1</sup> Para uma melhor compreensão acerca da gênese destes potenciais, vide a revisão sobre anatomia e fisiologia do sistema auditivo apresentada no Apêndice A.

potenciais evocados auditivos: a abordagem clássica e a abordagem bayesiana.

Depois da apresentação da revisão da literatura, o capítulo 3 mostra a metodologia utilizada no desenvolvimento dos detectores NP e bayesiano para as técnicas SFT e MSC. Em seguida, são abordados os procedimentos adotados na implementação de estimadores para a RSR, visando à aplicação dos detectores em registros ASSR. Por fim, é feita uma apresentação do banco de dados utilizado na validação dos detectores e uma breve descrição do algoritmo desenvolvido para o processamento dos registros de EEG.

Os resultados obtidos são apresentados no capítulo 4 e discutidos no capítulo 5. Por fim, o capítulo 6 traz as conclusões do trabalho e apresenta algumas propostas de trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

Este capítulo apresenta uma breve revisão acerca dos assuntos relacionados às áreas do conhecimento nas quais esse projeto se insere e os conceitos teóricos envolvidos no desenvolvimento da parte experimental.

### 2.1 POTENCIAIS EVOCADOS AUDITIVOS

Os potenciais evocados auditivos (PEA) são alterações observadas na atividade elétrica do sistema nervoso central desencadeadas por estímulos sonoros. A geração desses potenciais tem início quando o som atinge a cóclea e excita as células ciliadas internas (CCI) localizadas no órgão de Corti, desencadeando um processo de conversão da vibração mecânica em potenciais elétricos que são transmitidos até o córtex (vide a revisão sobre anatomia e fisiologia do sistema auditivo apresentada no Apêndice A). O trajeto percorrido por esses potenciais é complexo, envolvendo a passagem por diferentes vias ascendentes (ípsilaterais e contralaterais à orelha estimulada) e núcleos de retransmissão no tronco encefálico e tálamo.

Técnicas como a magnetoencefalografia (MEG) e a eletroencefalografia (EEG) possibilitam medir, de forma não invasiva, a manifestação dos PEA por meio de transdutores (biomagnetômetros e eletrodos) posicionados no couro cabeludo (VAUGHAN; RITTER, 1970; HARI et al., 1980).

A ocorrência dos PEA pode ser observada quando um indivíduo é submetido a uma estimulação sonora por pulsos de curta duração (também denominado *click*). O processamento dos registros de EEG permite verificar que o PEA desencadeado por esse estímulo é caracterizado por uma sequência de oscilações aperiódicas com duração aproximada de um segundo. Cada uma destas oscilações reflete a manifestação das diferentes estruturas neurais que compõem as vias auditivas à medida que esses potenciais se propagam em direção ao córtex. Por isso, cada uma delas é classificada com relação à sua latência e ao seu comportamento ao longo do tempo (PICTON, 2010).

A latência é o intervalo de tempo decorrido entre a apresentação do estímulo e a ocorrência de cada oscilação. As oscilações que se manifestam nos primeiros 15 ms são denominadas potenciais de curta latência. Já aquelas que ocorrem no intervalo entre

15 – 50 ms são classificadas como de média latência. As demais oscilações ( $> 50$  ms), por sua vez, são identificadas como de longa latência. (HALL III, 2015).

Embora ainda haja alguns debates acerca da localização precisa dos geradores, sabe-se que as células do gânglio espiral, o nervo auditivo, o núcleo coclear, o complexo olivar superior, o núcleo do lemnisco lateral e suas fibras que ascendem até o colículo inferior estão envolvidos na formação dos potenciais de curta latência. Por envolver estruturas do tronco encefálico, estas respostas são também denominadas como potenciais evocados auditivos do tronco encefálico (PEATE ou ABR, do inglês, *Auditory Brainstem Response*).

Já os potenciais de média latência envolvem o colículo inferior, a formação reticular, o núcleo geniculado medial e as regiões do córtex auditivo. Os potenciais de longa latência, por sua vez, envolvem a ativação de regiões do córtex auditivo bem como outras áreas corticais localizadas no lobo frontal e nos lobos parietais (HALL III, 2015; PICTON, 2010). Com relação ao comportamento ao longo do tempo, os PEAs podem receber duas denominações: potenciais transitórios e potenciais em regime permanente. As seções a seguir apresentam as características de cada uma delas.

### 2.1.1 Potenciais evocados auditivos transitórios

Os potenciais transitórios, como o próprio nome sugere, têm um comportamento transitório, sendo, portanto, caracterizados por uma sequência de oscilações não periódicas que se manifestam em um intervalo de tempo limitado. Este tipo de potencial pode ser observado quando são apresentados estímulos de curta duração espaçados por um intervalo de tempo longo o suficiente, de modo a permitir que as perturbações causadas por ele nas estruturas do sistema nervoso central se manifestem antes da chegada do próximo estímulo. Das respostas transitórias podem ser extraídas informações importantes que permitem avaliar diferentes aspectos relacionados à fisiologia do sistema nervoso.

Os PEATE, por exemplo, podem ser utilizados na avaliação da integridade do sistema auditivo, sobretudo em recém-nascidos. O propósito desta aplicação se deve à importância da detecção precoce de perdas auditivas nesses indivíduos, uma vez que o desenvolvimento da fala está diretamente relacionado à essa modalidade sensorial. O uso de tons puros de curta duração permite que os PEATE também sejam utilizados na estimulação de limiares auditivos (STAPELLES, 2000). Outras aplicações incluem o uso desses potenciais em monitoramentos cirúrgicos, na determinação de limiares auditivos e na identificação de perdas auditivas condutivas e neurosensoriais (KATZ et al., 2014).

Os potenciais de média e longa latência, por sua vez, vêm sendo utilizados em estudos que visam a relacionar alterações dessas respostas com disfunções cognitivas em decorrência de diferentes patologias do sistema nervoso central, como a doença de Alzheimer, a esquizofrenia, a esclerose múltipla (HONIG; RAMSAY; SHEREMATA, 1992),

a doença de Parkinson (PANG et al., 1990) e o autismo (COURCHESNE et al., 1984).

Uma característica comum às diferentes abordagens acerca dos potenciais transitórios está na forma como se dá a análise das respostas. De um modo geral, o processamento é realizado no domínio do tempo e as conclusões a serem tomadas envolvem a identificação das ondas pertinentes ao tipo de estudo conduzido, bem como a mensuração de amplitudes e latências de cada uma delas. É importante ressaltar que registros individuais de EEG possuem uma baixa relação sinal/ruído, o que inviabiliza a detecção das ondas que caracterizam os potenciais transitórios. A forma mais simples para atenuar o ruído é por meio do cálculo da média das respostas (sincronizadas com o estímulo – denominada média coerente ou promediacao temporal) obtidas de diversas repetições do estímulo. Deve-se assegurar que os registros estejam devidamente alinhados antes de se proceder com o cálculo da média. Caso contrário, a resposta resultante apresentará distorções que poderão levar a interpretações equivocadas (GATH; INBAR, 2013).

### 2.1.2 Potenciais evocados auditivos em regime permanente

Quando um estímulo periódico é apresentado a uma taxa de repetição elevada, não há tempo hábil para que a resposta evocada se manifeste por completo até a chegada do próximo estímulo. Nesses casos, observa-se uma sobreposição das respostas, resultando em um potencial em regime permanente, denominado ASSR (do inglês, *Auditory Steady-State Response*). Como são respostas sincronizadas, os potenciais em regime permanente apresentam-se como oscilações, também periódicas, que acompanham as variações de amplitude e/ou frequência presentes no estímulo.

O modelo proposto por Lins et al. (1995) permite compreender o efeito da estimulação por tons com amplitude modulada (AM) nas estruturas do sistema auditivo central e suas manifestações nos registros de EEG. Conforme apontam os autores, o estímulo sonoro do tipo tom AM é composto por três componentes espectrais, sendo uma delas localizada na frequência da portadora (maior energia e corresponde ao tom puro a ser avaliado no sistema auditivo), acompanhada de duas componentes laterais (uma de cada lado) cujo afastamento (em relação à portadora) é igual à frequência de modulação. Assim, por exemplo, um tom AM com portadora de 1.000 Hz, modulada a 80 Hz, apresentará uma componente em 1.000 Hz, outra em 920 Hz e uma terceira em 1.080 Hz. Os autores mostram que a sinalização das fibras aferentes será uma versão retificada do tom AM. A movimentação da membrana basilar em resposta ao tom AM resulta no deslocamento das CCI contra a membrana tectória, o que causa a deflexão dos cílios localizados no polo apical dessas células. Essa estimulação dos cílios é o fator responsável pela geração dos potenciais receptores que deflagrarão a sinalização neural até o córtex. Ressalta-se, no entanto, que esses potenciais se manifestam preferencialmente quando os cílios se deslocam em uma direção (quando comprimidos contra a membrana tectória). Consequentemente,

a sinalização gerada pelas CCI será uma versão retificada do tom AM, que apresentará uma quarta componente espectral localizada na frequência de modulação. A Figura 2 ilustra o modelo proposto por Lins et al. (1995) e o processamento do ASSR (que buscará a detecção da componente espectral correspondente a frequência de modulação).

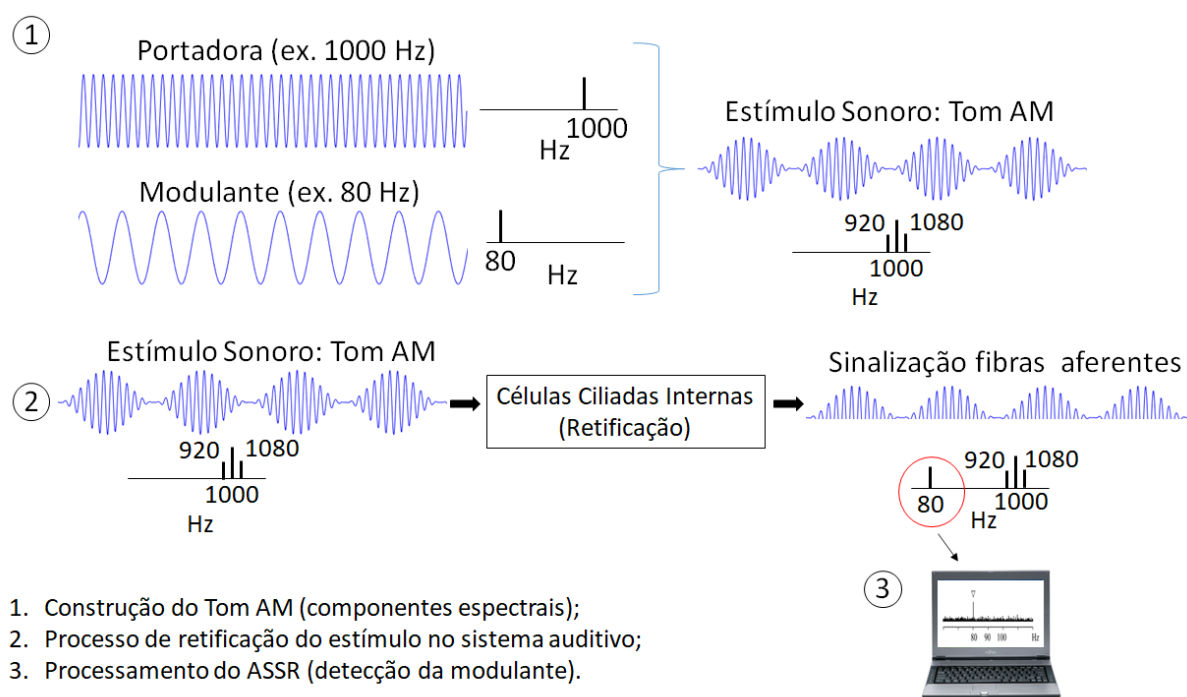


Figura 2 – Efeito da estimulação por tons com amplitude modulada (AM) nas estruturas do sistema auditivo central e suas manifestações nos registros de EEG.

Fonte: Elaborado pelo autor.

Desta forma, a identificação e análise dessas respostas se dá de forma distinta àquela utilizada nos potenciais transitórios. Em vez de demandar um profissional capacitado para a identificação de picos e latências em registros realizados no domínio do tempo, como se faz nos potenciais transitórios, as repostas em regime permanente podem ser analisadas de forma objetiva e automática, no domínio da frequência, monitorando-se a magnitude e/ou a fase, de componentes espectrais específicas. É importante destacar que a aplicação das técnicas de processamento tanto no domínio do tempo (potenciais transitórios) quanto no domínio da frequência (potenciais em regime permanente), abordadas no presente estudo, partem da premissa que os PEA são processos estacionários.

O estudo conduzido por Galambos, Makeig e Talmachoff (1981) é considerado um marco no desenvolvimento da técnica ASSR, sobretudo para sua utilização na determinação de limiares auditivos. No referido trabalho foram utilizados estímulos do tipo tom *burst* (tons puros de curta duração apresentados em intervalos de tempo constantes) para a obtenção das respostas evocadas. Os resultados mostraram que os potenciais registrados se apresentavam como sinais senoidais com frequência igual à taxa de apresentação dos

estímulos, resultantes da sobreposição de potenciais de média latência.

Os autores investigaram também a influência dos parâmetros de estimulação (intensidade sonora, frequência do tom puro e taxa de apresentação) nas respostas ASSR. Mostrou-se que a amplitude das respostas estava diretamente relacionada à intensidade do estímulo. Com relação à frequência de estimulação, foram testados tons de 250 Hz, 500 Hz, 2.500 Hz e 5.000 Hz, todos apresentados a uma taxa de repetição de 40 Hz. Observou-se que as respostas apresentavam maior amplitude para estímulos com frequências mais baixas. Em uma terceira abordagem dentro do mesmo estudo, manteve-se constante a intensidade e a frequência do estímulo, variando-se apenas a taxa de repetição (considerando valores no intervalo entre 10 Hz e 55 Hz). Observou-se, neste caso, que as maiores respostas evocadas ocorreram nas frequências próximas a 40 Hz.

Desde então, o ASSR tem sido investigado sob diferentes paradigmas, que buscam o aprimoramento da técnica, sobretudo, pela redução do tempo necessário para a obtenção das respostas evocadas. Variações na forma de onda do estímulo, na intensidade sonora, nas frequências de estimulação, na forma de apresentação (estimulação simples ou estimulação múltipla) e no método utilizado no processamento das respostas são alguns dos aspectos que vem sendo explorados para tal finalidade.

Com relação à forma de onda, além do tom *burst*, utiliza-se também os tons puros modulados em amplitude (AM) e em frequência (FM) (JOHN et al., 2001; JOHN; PICTON, 2000; REES; GREEN; KAY, 1986; ROSS et al., 2000), os tons mistos (modulados em amplitude e em frequência pela mesma taxa de modulação, identificados pela sigla MM) (DIMITRIJEVIC et al., 2001), os tons AM com envelope exponencial (JOHN; DIMITRIJEVIC; PICTON, 2002) e os tons modulados simultaneamente em amplitude e frequência com taxas de modulação distintas (IAFM) (DIMITRIJEVIC et al., 2001). Há ainda estímulos que utilizam as diferentes modulações supracitadas (AM, FM, MM e IAFM) tendo como portadora sinais de ruído, em vez de tons puros (JOHN; DIMITRIJEVIC; PICTON, 2003; SANTOS et al., 2016). Stürzebecher et al. (2006) apresentaram um novo tipo de estímulo, conhecido como *Chirp*, cuja gênese é dada pela sobreposição de tons puros com mesma amplitude, porém defasados de tal forma a compensar o atraso de propagação das ondas sonoras no interior da cóclea. Os resultados obtidos em seus estudos mostraram que as respostas ao *Chirp* apresentaram uma relação sinal/ruído superior àquela observada com estímulos do tipo AM. Segundo os autores, o atraso de propagação considerado na formação do estímulo possibilita que grupos de células ciliadas sejam ativadas de forma síncrona, o que contribui na elevação da amplitude das respostas medidas.

Picton, Van Roon e John (2007) e Rodriguez et al. (1986) investigaram a influência da intensidade do estímulo sonoro e observaram um aumento na amplitude e uma diminuição na latência das respostas evocadas à medida que se eleva esse parâmetro. Os autores também observaram que a taxa de variação da amplitude do ASSR em relação à



intensidade (inclinação da reta intensidade-amplitude) é mais acentuada para tons com frequências mais baixas.

Com relação às frequências de estimulação, Lins et al. (1995) avaliaram as respostas em regime permanente para tons de 1 kHz modulados em amplitude por frequências cuja variação se deu na faixa entre 67 Hz – 111 Hz. Verificou-se que as respostas para as frequências de modulação entre 80 Hz e 95 Hz apresentaram as maiores amplitudes. Achados semelhantes foram observados por Purcell e John (2010). Galambos, Makeig e Talmachoff (1981), assim como Aoyagi et al. (1993b), haviam observado que as maiores amplitudes das respostas evocadas ocorrem para frequências de modulação próximas a 40 Hz. Entretanto, as respostas nessa faixa são afetadas pelo estado de vigília do indivíduo (caindo significativamente durante o sono) e pelo uso de anestésicos. Além disso, conforme mostrado por Maurizi et al. (1990), as respostas em 40 Hz são mais difíceis de detecção em crianças e recém-nascidos. Ross et al. (2003) observaram ainda uma variabilidade da amplitude do ASSR em função das frequências de portadora quando são utilizadas modulantes próximas a 40 Hz.

Lins e Picton (1995) bem como John et al. (1998) compararam as respostas evocadas por estimulação simples e estimulação múltipla. Os autores mostraram que, em relação à estimulação simples, não houve redução significativa na amplitude das respostas evocadas quando foram utilizados até quatro estímulos simultâneos por orelha, respeitando-se o espaçamento mínimo de uma oitava entre as portadoras e de 1,3 Hz entre as modulantes e o uso de intensidades abaixo de 60 dB<sub>SPL</sub> (*Sound Pressure Level*). Tal achado atraiu ainda mais atenção para os potenciais evocados em regime permanente pela possibilidade de sua utilização na estimação de limiares auditivos de forma mais rápida, se comparado ao procedimento utilizado na audiometria tonal (que avalia uma frequência por vez).

Além dos trabalhos dedicados ao aprimoramento da técnica propriamente dita, há diversos outros que, por sua vez, buscam compreender as bases fisiológicas envolvidas na gênese e na propagação do ASSR nas diferentes estruturas do sistema nervoso, de modo a utilizar essas repostas em aplicações clínicas. Uma destas aplicações está no levantamento de limiares auditivos. Lins et al. (1996) utilizaram tons modulados em amplitude na faixa entre 75 Hz e 110 Hz para o levantamento de limiares auditivos fisiológicos em indivíduos normais e com perdas auditivas, tanto por via aérea quanto por via óssea. Os resultados mostraram que os limiares obtidos por meio do ASSR para todos os casos foram superiores aos limiares da audiometria tonal. Diversos outros estudos também reportam limiares superiores para o ASSR, embora as diferenças encontradas tenham sido diferentes (HERDMAN; STAPELLS, 2001; SCHMULIAN; SWANEPOEL; HUGO, 2005).

Van Maanen e Stapells (2005) e Jafarzadeh, Jalaie e Kamali (2008) utilizaram frequências de modulação próximas a 40 Hz (no intervalo entre 36,7 Hz – 45 Hz) em

indivíduos com e sem perdas auditivas. Em ambos os estudos se observou que os limiares encontrados em 40 Hz foram mais próximos aos da audiometria tonal se comparados aos tons modulados próximos a 80 Hz. Além disso, notou-se que os indivíduos com perdas auditivas apresentaram as menores diferenças entre limiares.

Observa-se também grande interesse no uso do ASSR na triagem auditiva em neonatos e no levantamento de limiares auditivos em crianças na primeira infância (RICKARDS et al., 1994; LINS et al., 1996; RESENDE et al., 2015; FRANÇOIS et al., 2016). O principal propósito desses estudos está na detecção precoce de deficiência auditivas de modo a evitar o comprometimento do desenvolvimento da fala e da linguagem nesses indivíduos.

O ASSR modulado a 40 Hz vem sendo utilizado em estudos relacionados a doenças do sistema nervoso central. Tsuchimoto et al. (2011) observaram uma redução na potência das respostas evocadas por *clicks* na faixa de 40 Hz em indivíduos com esquizofrenia. Os autores concluem que essas alterações se devem a anomalias no circuito neural causadas pela doença. Van Deursen et al. (2011) conduziram um estudo no qual foram comparadas as repostas evocadas por *clicks* a 40 Hz entre idosos saudáveis e idosos portadores da doença de Alzheimer. Observou-se que os indivíduos doentes apresentaram um aumento nas repostas evocadas, o que levou os autores a sugerirem que os ASSR pode ser utilizado como um marcador para acompanhar a progressão da doença.

Outras aplicações envolvem o monitoramento das repostas ASSR durante a realização de tarefas cognitivas. Ross et al. (2004), assim como Skosnik, Krishnan e O'Donnell (2007) observaram que as repostas ASSR para estímulos modulados na faixa de 40 Hz apresentaram um aumento na amplitude e no sincronismo quando os indivíduos estavam atentos a um estímulo sonoro. Voicikas et al. (2016) avaliaram a influência do tipo de estímulo sonoro utilizado nas repostas evocadas nesse contexto e constataram que as repostas a 40 Hz para tons AM se mantiveram estáveis, ou seja, não se alteraram em função do estado de atenção dos indivíduos. Por outro lado, observou-se que as repostas aos estímulos do tipo *click* apresentaram variações de amplitude e sincronismo quando os indivíduos estavam distraídos. Yokota e Naruse (2015) mostraram que as repostas ASSR apresentaram variações de amplitude e sincronismos de fase em função da dificuldade associada à tarefa cognitiva. Os autores apontam que, quanto mais complexa é a tarefa, menor é a resposta evocada medida.

A variação da resposta ASSR 40 Hz em função do estado de atenção têm estimulado a aplicação desses potenciais na implementação de interfaces cérebro máquina (ICM). O uso de repostas evocadas auditivas tem surgido como uma alternativa às ICMs baseadas em estímulos visuais, sobretudo em situações nas quais os indivíduos apresentam deficiências como a perda da visão ou da capacidade de controle motor do globo ocular. Kim et al. (2011) utilizaram dois tons *bursts* com taxas de repetição de 37 Hz e 43 Hz, apresentados

em alto-falantes localizados, respectivamente, à esquerda e à direita dos participantes do experimento. Os indivíduos receberam instruções para que atentassem para o estímulo sonoro proveniente de um dos dois alto-falantes. O lado para o qual o indivíduo deveria prestar atenção era informado via estímulo sonoro e obedecia a uma sequência aleatória. Os resultados mostraram que as respostas evocadas apresentaram maior amplitude na frequência correspondente ao estímulo atentado. Com isso, a interface cérebro máquina implementada obteve índices de classificação altos o suficiente para ser aplicada em problemas de decisão entre dois estímulos concorrentes.

Embora os resultados sejam promissores, o desempenho de ICM baseadas em potenciais evocados auditivos é ainda inferior àquelas baseadas em potenciais evocados visuais. Visando o aprimoramento das interfaces comandadas por estímulos sonoros, Kaongoen e Jo (2017) propuseram uma ICM híbrida que utiliza tanto as respostas ASSR quanto os potenciais P300, de longa latência. Os resultados obtidos pelos autores mostram que a ICM implementada apresentou uma acurácia de 85,33% e uma taxa de transferência de informação (TTI) de 9,11 bits/minuto. Esses índices são superiores àqueles obtidos por ICM baseadas somente em ASSR (acurácia de 66,68% e TTI de 2,01 bits/min) ou no P300 (acurácia de 74,58% e TTI de 4,18 bits/min). Outros estudos têm investigado a influência do tipo de estímulo sonoro no desempenho de ICM baseadas em ASSR. Heo et al. (2017) utilizaram sons de instrumentos musicais (violino e piano) e sons naturais (canto de cigarras e curso de água) modulados em amplitude e compararam o desempenho da ICM a estes estímulos em relação a tons puros modulados em amplitude (tons AM). Os resultados mostraram que os estímulos naturais apresentaram maiores taxas de acerto se comparados aos tons puros. Segundo apontam os autores, isso se deve ao fato dos participantes se sentirem mais confortáveis quando submetidos a sons considerados familiares.

Como mencionado anteriormente, a natureza periódica do ASSR possibilita a identificação de respostas evocadas por meio de métodos no domínio da frequência. Nesse caso, buscar-se-ão aquelas componentes espectrais que representam as variações de amplitude e/ou frequência do estímulo e que serão percebidas e acompanhadas pelo sistema nervoso. Entretanto, assim como descrito para os potenciais transitórios, o ASSR também apresenta uma baixa relação sinal/ruído e, da mesma forma, demanda estratégias que possibilitem a redução do ruído de fundo de modo a viabilizar a detecção dos potenciais evocados.

Um procedimento utilizado para este fim envolve a repetição do protocolo experimental  $N$  vezes, sucedida pela realização da promediação temporal de todos os registros coletados, o que promove um aumento da relação sinal/ruído por um fator igual à  $N$ . John, Dimitrijevic e Picton (2001) verificaram que o uso de médias ponderadas pela variância de cada registro proporciona um aumento ainda mais eficiente da RSR. Além do cálculo de médias, outras abordagens para a melhoria da RSR incluem o uso de transformadas

Wavelets (CAUSEVIC et al., 2005), filtros de Wiener (VAN DUN; WOUTERS; MOONEN, 2007) e análise de componentes independentes (VAN DUN; WOUTERS; MOONEN, 2006).

Como o ruído de fundo se distribui por todo o espectro, é necessária a utilização de métodos estatísticos que possibilitem inferir se as manifestações observadas nas componentes de frequências de interesse são causadas pela presença de uma resposta ou se representam apenas variações aleatórias do EEG. Dentre os métodos utilizados para a detecção objetiva do ASSR no domínio da frequência destacam-se o Teste Espectral F (SFT) (ZUREK, 1992), a Magnitude Quadrática da Coerência (MSC) (DOBIE; WILSON, 1989), a Medida de componente síncrona (do inglês, *Component Synchrony Measure* – CSM, também denominada *Phase Synchrony Measure* – PSM) (AOYAGI et al., 1993a), o Teste  $T^2$  - Circular ( $T^2$ Circ) (VICTOR; MAST, 1991) e a análise de variância (ANOVA) (PÉREZ-ABALO et al., 2013).

Dobie e Wilson (1996) realizaram simulações com sinais resultantes da sobreposição de um tom puro com ruído branco gaussiano e observaram que a MSC e SFT apresentaram desempenho equivalentes. Os mesmos autores, em um trabalho anterior (DOBIE; WILSON, 1993), haviam demonstrado que o teste  $T^2$ Circ é uma transformação algébrica de MSC e que, desta forma, os dois métodos apresentam desempenhos iguais. Por outro lado, Leite, Simpson e Infantosi (1996) e Simpson et al. (2000) utilizaram o SFT, a MSC e o CSM na detecção de potenciais evocados somatossensoriais. Os autores concluíram que a MSC e o CSM obtiveram desempenhos melhores que SFT e que, entre esses dois primeiros, a MSC foi ligeiramente superior à CSM. De forma semelhante, Melges, Infantosi e Miranda de Sá (2011) também não observaram diferenças significativas de desempenho entre o CSM e a MSC, no estudo envolvendo os potenciais evocados pela estimulação do nervo tibial. Valdes et al. (1997) avaliaram o desempenho de  $T^2$ circ, CSM e SFT quando aplicados em potenciais evocados auditivos em regime permanente e não observaram diferenças significativas nas performances desses métodos para a detecção de respostas.

Apesar das diversas conclusões a respeito dos métodos supracitados, observa-se que a MSC figura entre aqueles que apresentam o melhor desempenho nas diferentes aplicações revisadas (simulações computacionais, potenciais evocados somatossensoriais e potenciais evocados auditivos). Por outro lado, no contexto dos potenciais evocados auditivos em regime permanente, nota-se que o SFT é um dos mais empregados dentre as técnicas de detecção. Isso se deve, principalmente, à grande difusão do sistema desenvolvido por John et al. (1998), denominado *Multiple Auditory Steady-State Responses* (MASTER), que utiliza esse teste para o processamento dos registros. Os desenvolvedores desse sistema indicam sua preferência por SFT em relação aos demais métodos, alegando que essa técnica proporciona uma flexibilidade na escolha das componentes espectrais para a estimação do ruído de fundo, o que favorece a realização dos cálculos para a detecção das respostas (PICTON et al., 2003).

Com base nessas constatações, a seguir, é apresentada uma breve revisão sobre as formulações matemáticas de SFT e MSC.

### 2.1.2.1 Teste Espectral F (SFT)

No contexto dos potenciais evocados, o SFT é um teste estatístico utilizado para comparar a potência da componente espectral na qual se espera encontrar uma resposta evocada em relação a potência do ruído de fundo do EEG. Como o ruído se distribui em todo o espectro, sua potência é estimada pela média de  $M$  componentes adjacentes àquela na qual se acredita haver resposta (ZUREK, 1992), sendo escolhidas, normalmente,  $M/2$  componentes à esquerda e outras  $M/2$  componentes à direita. Baseado em Zurek (1992), pode-se estimar SFT por meio da equação 1:

$$\hat{\phi}(f_0) = \frac{|X(f_0)|^2}{\frac{1}{M} \sum_{\substack{i=0-M/2 \\ i \neq 0}}^{0+M/2} |X(f_i)|^2} \quad (1)$$

Sendo  $X(f_0)$  a transformada de Fourier avaliada na componente espectral  $f_0$  na qual se espera encontrar uma resposta;  $X(f_i)$  a transformada de Fourier avaliada na  $i$ -ésima componente espectral adjacente à  $f_0$ ; e  $M$  o número de componentes espectrais utilizado na estimação da potência do ruído. O sobrescrito “ $\hat{\phantom{x}}$ ” indica se tratar de um cálculo estimado.

Ainda conforme Zurek (1992), na hipótese de ausência de respostas evocadas ( $H_0$ ), as amostras de  $\hat{\phi}(f_0)$  seguirão a distribuição F, conforme apresentado a seguir (equação 2):

$$\hat{\phi}(f_0) \Big|_{H_0} \sim F_{2,2M} \quad (2)$$

Sendo  $F_{2,2M}$  a distribuição F com 2 e  $2M$  graus de liberdade.

Quando os valores estimados para o teste F forem maiores ou iguais ao limiar de decisão ( $\hat{\phi}(f_0) \geq \phi_{crit}$ ), será rejeitada a hipótese  $H_0$  e, conseqüentemente, é considerada a presença de respostas evocadas. Miranda de Sá et al. (2009) mostram que, na presença de respostas evocadas (hipótese alternativa  $H_1$ ), o intervalo de confiança do teste F pode ser determinado a partir da distribuição F não central, dada a seguir (equação 3):

$$\hat{\phi}(f_0) \Big|_{H_1} \sim F'_{2,2M}(\lambda = 2 \cdot RSR) \quad (3)$$

Sendo  $F'$  a distribuição F não central; 2 e  $2M$  os graus de liberdade;  $\lambda$  o parâmetro de não centralidade; e  $RSR$  a relação sinal/ruído, cujo valor, conforme demonstram Dobie e

Wilson (1996), pode ser estimado pela seguinte relação:

$$\widehat{RSR} = \hat{\phi}(f_0) - 1 \quad (4)$$

Desta forma, considerando um nível de significância  $\alpha$ , pode-se determinar os limites do intervalo de confiança de  $\hat{\phi}(f_0)$  para a hipótese  $H1$  a partir da probabilidade de cauda direita ( $Q$ ), obtidos da função de distribuição acumulada de  $F'_{2,2M}(\lambda)$ , conforme exposto a seguir:

$$\begin{aligned} Limite_{\text{inf}} &= Q^{-1}\left(\frac{\alpha}{2}\right) \\ Limite_{\text{sup}} &= Q^{-1}\left(1 - \frac{\alpha}{2}\right) \end{aligned} \quad (5)$$

O valor esperado da distribuição F não central é dado por:

$$E[\phi(f_0)|_{H1}] = \frac{v_2(v_1 + \lambda)}{v_1(v_2 - 2)}; \quad v_2 > 2 \quad (6)$$

Considerando  $v_1 = 2$ ,  $v_2 = 2M$  e  $\lambda = 2 \cdot RSR$ , obtém-se:

$$E[\phi(f_0)|_{H1}] = \frac{2M(2 + 2 \cdot RSR)}{2(2M - 2)} = \frac{M(1 + RSR)}{(M - 1)}; \quad M > 1 \quad (7)$$

### 2.1.2.2 Magnitude Quadrática da Coerência (MSC)

Segundo Dobie e Wilson (1989), a função magnitude quadrática da coerência permite avaliar a dependência linear entre as componentes espectrais de dois sinais distintos. No contexto dos potenciais evocados auditivos, considera-se esses dois sinais como sendo uma entrada,  $x(t)$ , que representa o estímulo apresentado, e uma saída,  $y(t)$ , que representa o sinal de EEG medido durante a estimulação. Sua formulação se dá a partir da função densidade espectral de potência cruzada entre  $x(t)$  e  $y(t)$ , que pode ser descrita da seguinte forma:

$$G_{xy}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} E[X^*(f)Y(f)] \quad (8)$$

Sendo  $X^*(f)$  o conjugado da transformada de Fourier de  $x(t)$  e  $Y(f)$  a transformada de Fourier de  $y(t)$ .

Essa medida pode ser normalizada, por meio das funções densidade espectral de potência de  $x(t)$  e  $y(t)$ , resultando na função de coerência complexa, dada por:

$$\gamma_{xy}(f) = \frac{G_{xy}(f)}{\sqrt{G_{xx}(f)G_{yy}(f)}} \quad (9)$$

Sendo  $G_{xx}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} E[|X(f)|^2]$  e  $G_{yy}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} E[|Y(f)|^2]$ , respectivamente, as densidades espectrais de potência de  $x(t)$  e  $y(t)$ . Tomando-se a magnitude ao quadrado da função de coerência complexa, chega-se à MSC:

$$\gamma^2_{xy}(f) = \frac{|G_{xy}(f)|^2}{G_{xx}(f)G_{yy}(f)} \quad (10)$$

Em situações reais não é possível proceder com o cálculo exato das funções densidade espectral de potência  $G_{xy}(f)$ ,  $G_{xx}(f)$  e  $G_{yy}(f)$  haja vista que os dados disponíveis são finitos. Assim, conforme descrevem Dobie e Wilson (1989), uma forma de se estimar essas funções se dá a partir do cálculo da média das densidades espectrais de potência tomadas de  $N$  realizações de  $x(t)$  e  $y(t)$ , conforme apresentado a seguir:

$$\begin{aligned} \hat{G}_{xy}(f) &= \frac{1}{N} \sum_{i=1}^N X_i^*(f) Y_i(f) \\ \hat{G}_{xx}(f) &= \frac{1}{N} \sum_{i=1}^N |X_i(f)|^2 \\ \hat{G}_{yy}(f) &= \frac{1}{N} \sum_{i=1}^N |Y_i(f)|^2 \end{aligned} \quad (11)$$

Onde o sobrescrito “^” indica se tratar de um cálculo estimado.

Procedendo dessa forma, chega-se à estimativa da MSC, cuja equação é dada por:

$$\gamma^2_{xy}(f) = \frac{|\hat{G}_{xy}(f)|^2}{\hat{G}_{xx}(f)\hat{G}_{yy}(f)} = \frac{\left| \sum_{i=1}^N X_i^*(f) Y_i(f) \right|^2}{\left( \sum_{i=1}^N |X_i(f)|^2 \right) \left( \sum_{i=1}^N |Y_i(f)|^2 \right)} \quad (12)$$

Uma situação especial ocorre quando o sinal  $x(t)$  é periódico determinístico (por exemplo, um estímulo sonoro AM) e há um sincronismo entre todas as  $N$  realizações. Neste caso, observa-se que os registros  $X_i(f)$  serão considerados idênticos, o que permite uma simplificação no cálculo da MSC, resultando na seguinte equação (MIRANDA DE SÁ; INFANTOSI, 2002; SIMPSON et al., 2000):

$$\hat{k}^2(f_0) = \frac{\left| \sum_{i=1}^N Y_i(f_0) \right|^2}{N \sum_{i=1}^N |Y_i(f_0)|^2} \quad (13)$$

Sendo  $\hat{k}^2(f_0)$  a estimativa da MSC na componente espectral  $f_0$  para este caso específico (por exemplo, do sinal de EEG registrado no couro cabeludo durante estimulação auditiva por tons AM).

Miranda de Sá (2004) demonstrou que as amostras de  $\hat{k}^2(f_0)$ , para  $H1$ , se distribuem de acordo com a função Beta não central, cuja parametrização é dada por:

$$\hat{k}^2(f_0) \Big|_{H1} \sim ncbeta(1, N - 1, 2N \cdot RSR) \quad (14)$$

Sendo “ncbeta” a distribuição beta não central; 1 e  $N - 1$  os parâmetros de forma; e  $2N \cdot RSR$  o parâmetro de não centralidade desta distribuição.

Segundo Miranda de Sá e Infantosi (2002), a relação sinal/ruído pode ser estimada a partir da coerência com base na seguinte relação:

$$\widehat{RSR} = \frac{\hat{k}^2(f_0)}{1 - \hat{k}^2(f_0)} \quad (15)$$

Na hipótese de não haver respostas evocadas ( $H0$ ) nos registros de EEG, o valor da MSC é considerado nulo ( $k^2(f_0) = 0$ ). Conseqüentemente, o parâmetro de não centralidade também será nulo, levando  $\hat{k}^2$  a ser descrita pela distribuição Beta ( $\hat{k}^2(f_0) \Big|_{H0} \sim beta(1, N - 1)$ ).

Considerando um nível de significância  $\alpha$ , o limiar de decisão para essa hipótese pode ser obtido a partir da função de distribuição acumulada de  $beta(1, N - 1)$ , resultando em:

$$k_{crit}^2 = 1 - \alpha^{(1/(N-1))} \quad (16)$$

Caso o valor estimado para a coerência exceda o limiar de decisão ( $\hat{k}^2(f_0) \geq k_{crit}^2$ ), a hipótese  $H0$  é rejeitada e, conseqüentemente, será considerada a existência de uma resposta evocada.

Neste caso, é possível estimar o intervalo de confiança de  $\hat{k}^2(f_0)$  para  $H1$  a partir da distribuição beta não central apresentada anteriormente na equação 14. Levando-se em consideração o nível de significância ( $\alpha$ ) adotado no teste, pode-se determinar os limites inferior e superior deste intervalo de confiança da seguinte forma:

$$\begin{aligned} Limite_{inf} &= Q^{-1}\left(\frac{\alpha}{2}\right) \\ Limite_{sup} &= Q^{-1}\left(1 - \frac{\alpha}{2}\right) \end{aligned} \quad (17)$$

## 2.2 INFERÊNCIA BAYESIANA

A base teórica da inferência bayesiana remonta ao século XVIII, quando os ensaios do reverendo Thomas Bayes foram publicados por Richard Price em 1763 (BAYES; PRICE, 1763). Porém, esta teoria ganhou notoriedade quando Laplace publicou seus estudos relacionados à inferência de parâmetros (probabilidade inversa), quando foi dado um tratamento matemático mais elaborado a estas ideias (LAPLACE; DALE, 1995).



A principal característica dessa abordagem está no uso de aspectos subjetivos, baseado em experiências anteriores ou até mesmo na intuição, para fornecer informações a priori sobre o fenômeno estudado. Este conhecimento prévio é então combinado às observações realizadas e estas duas informações são utilizadas para possibilitar a inferência sobre estes parâmetros.

Utilizando a notação matemática, pode-se representar a inferência bayesiana através da seguinte relação:

$$f(\theta|x) \propto f(\theta) f(x|\theta) \quad (18)$$

Sendo  $f(\theta)$  a distribuição a priori do parâmetro  $\theta$ , que representa o conhecimento prévio que se tem sobre o fenômeno observado;  $f(x|\theta)$  a função de verossimilhança; e  $f(\theta|x)$  a chamada distribuição a posteriori que será utilizada para estimar o parâmetro a partir da observação das amostras  $x$ . O símbolo  $\propto$  indica a relação de proporcionalidade entre as distribuições de probabilidade (HOFF, 2009).

Do início do século XX até a década de 1980, houve avanços no desenvolvimento da inferência bayesiana, sobretudo na forma de quantificar o conhecimento a priori. Contudo, a sua aplicação estava restrita a problemas cujas distribuições fossem funções conhecidas ou que tivessem um número reduzido de parâmetros para serem estimados por meio de métodos de integração numérica (CONGDON, 2014; CARLIN; LOUIS, 2008). A grande disseminação da teoria bayesiana ocorreu a partir das décadas de 1980 e 1990, com o expressivo aumento da capacidade de processamento dos computadores acompanhado do desenvolvimento de algoritmos de simulação, sobretudo os Métodos Monte Carlo via cadeias de Markov (GELFAND; SMITH, 1990; GILKS; RICHARDSON; SPIEGELHALTER, 1996).

Diferentemente da abordagem frequentista, que preconiza a repetição de um mesmo experimento diversas vezes para efetuar a estimação de parâmetros, a inferência bayesiana é capaz de realizar estas estimativas sempre que um novo dado é obtido. Esta forma de abordagem se mostra muito adequada em diversas situações práticas nas quais a repetição não é possível, ou seja, uma decisão precisa ser tomada tendo em mãos apenas o evento presente e o conhecimento prévio sobre o fenômeno estudado (LEAMER, 1991; TEBALDI et al., 2005; TRUCCO et al., 2008). Além disso, a formulação bayesiana considera que os parâmetros investigados, além de desconhecidos, são também de natureza aleatória.

Por outro lado, o desempenho de uma estimativa sob o paradigma bayesiano apresenta dependência em relação ao conhecimento prévio, que está descrito na distribuição a priori (JAYNES, 1968). Em algumas situações, entretanto, este conhecimento não é adequadamente representado pelas distribuições clássicas (Normal, Uniforme, Poisson, Binomial, entre outras), tornando-se necessária a elaboração de um modelo capaz de

descrever em termos matemáticos a informação prévia que se tem. Como consequência, a complexidade do problema pode aumentar consideravelmente, podendo haver situações nas quais até mesmo o cálculo computacional ainda não é possível. Em outros casos, opta-se por diminuir a complexidade do modelo, assumindo que o conhecimento a priori segue uma distribuição conhecida, tendo como contrapartida uma redução da influência desta informação na determinação da distribuição a posteriori dos parâmetros de interesse (SYVERSVEEN, 1998).

Há ainda situações nas quais a distribuição a priori é conhecida, porém a função de verossimilhança não apresenta uma forma analítica conhecida. Nestes casos, até mesmo técnicas computacionais como os métodos Monte Carlo podem não ser capazes de realizar inferências sobre os parâmetros de interesse. Para estas situações, é necessário o uso de métodos conhecidos como *Approximate Bayesian Computation* (ABC) que têm como principal característica a capacidade de estimar as distribuições a posteriori sem o conhecimento da função de verossimilhança (LEUENBERGER; WEGMANN, 2010; MARIN et al., 2012). A seguir são apresentadas algumas abordagens utilizadas na estimação das distribuições que compõem a formulação bayesiana.

### 2.2.1 Distribuições a priori

A formulação de Bayes não especifica como as distribuições a priori devem ser formuladas e, desde o surgimento dessa teoria, diversos métodos foram desenvolvidos para quantificar esse conhecimento prévio.

Historicamente, há dois pontos de vista a respeito do papel da distribuição a priori na construção de modelos. Um deles entende que a escolha das distribuições a priori deve ser feita por meio de regras formais (abordagem objetiva) (KASS; WASSERMAN, 1996), enquanto o outro entende ser relevante a inclusão do conhecimento prévio que se tem a respeito do fenômeno em questão, seja este conhecimento oriundo de um especialista ou de resultados de experimentos anteriores (abordagem subjetiva) (GARTHWAITE; KADANE; O'HAGAN, 2005).

#### 2.2.1.1 Abordagem Objetiva

Na abordagem objetiva (também denominada não-informativa) há o entendimento de que a informação a respeito dos parâmetros desconhecidos deve vir dos dados e, desta forma, as distribuições a priori devem ser minimamente informativas. Dentre os principais métodos propostos, destacam-se o princípio da razão insuficiente de Laplace, as prioris de Jeffreys, o método de Bernardo e Berger e o princípio da máxima entropia (ALSTON et al., 2012; CARLIN; LOUIS, 2008; ROBERT, 2007; KASS; WASSERMAN, 1996).

### 2.2.1.1.1 O princípio da razão insuficiente

O uso do princípio da razão insuficiente (ou regra de Laplace) remonta ao período quando Laplace formulou a abordagem bayesiana para a probabilidade. Esse princípio diz que, caso não haja uma razão para assumir que um evento seja mais provável de ocorrer dentre diversos outros mutuamente exclusivos, deve-se considerar que todos os eventos são equiprováveis (BARNETT, 1999). Desta forma, atribui-se aos parâmetros do modelo probabilidades a priori com distribuições uniformes.

Embora seja um método amplamente empregado, a regra de Laplace recebe críticas com relação à possibilidade de lidar com distribuições impróprias quando, por exemplo, o intervalo do parâmetro de interesse é ilimitado. Além disso, esse método não é invariante por reparametrização, ou seja, transformações no parâmetro de interesse podem resultar em distribuições a priori que não sejam constantes (ROBERT, 2007).

### 2.2.1.1.2 Método de Jeffreys

A abordagem de Jeffreys trouxe refinamentos à regra de Laplace, sobretudo, em relação à invariância por reparametrização. Seu trabalho buscou a concepção de uma regra geral que pudesse ser aplicada para a determinação de distribuição a priori. Esta distribuição é dada por (CARLIN; LOUIS, 2008):

$$\pi(\theta) \propto \mathbf{I}(\theta)^{\frac{1}{2}} \quad (19)$$

Sendo  $\mathbf{I}(\theta)$  a matriz de informação de Fisher, que é dada por:

$$\mathbf{I}(\theta) = -E \left[ \frac{\partial^2 \log f(x|\theta)}{\partial \theta^2} \right] \quad (20)$$

Sendo  $E[.]$  o valor esperado e  $f(x|\theta)$  a função de verossimilhança.

Assim, informação de Fisher permite mensurar a quantidade de informação que a variável aleatória  $x$  traz a respeito do parâmetro  $\theta$  (ROBERT, 2007).

### 2.2.1.1.3 Método de Bernardo e Berger

O método de Bernardo e Berger propõe a formulação de distribuições a priori, por meio de uma abordagem denominada Priori de Referência. Essa abordagem envolve duas modificações no método de Jeffreys, sendo a primeira a distinção no modelo entre os parâmetros de interesse e os parâmetros perturbadores (*nuisance*), enquanto a segunda envolve a definição do conceito de informação ausente (*missing information*).

Segundo mostram Kass e Wasserman (1996),  $\theta$  pode ser considerado em função desses dois parâmetros,  $\theta = (w, \lambda)$ , sendo  $w$  o parâmetro de interesse e  $\lambda$  o parâmetro perturbador (aquele para o qual a inferência não é desejada, mas que deve ser levado em conta no modelo). Define-se então  $\pi(\lambda|w)$  como sendo a priori de Jeffreys associada a  $p(x|\theta)$  quando  $w$  é fixo. Em seguida, deve-se determinar a distribuição marginal  $p(x|w) = \int p(x|w, \lambda)\pi(\lambda|w)d\lambda$ . A partir da distribuição marginal, calcula-se então a priori de Jeffreys  $\pi(w)$  associada a  $p(x|w)$ . A priori recomendada será então  $\pi(\theta) = \pi(w)\pi(\lambda|w)$ , que é dada por:

$$\pi(\theta) \propto j_w(\lambda) \exp \left\{ \int j_w(\lambda) \log(S(w, \lambda)) d\lambda \right\} \quad (21)$$

Sendo  $j_w(\lambda)$  a priori de Jeffreys para  $\lambda$  quando  $w$  é fixo e:

$$S = \sqrt{\frac{|\mathbf{I}|}{|\mathbf{I}_{22}|}} \quad (22)$$

Sendo  $\mathbf{I}$  a matriz de informação de Fisher e  $\mathbf{I}_{22}$  a parcela de  $\mathbf{I}$  referente ao parâmetro perturbador ( $\mathbf{I} = \begin{pmatrix} \mathbf{I}_{11} & \mathbf{I}_{12} \\ \mathbf{I}_{21} & \mathbf{I}_{22} \end{pmatrix}$ ).

A determinação da informação ausente se baseia na distância entre as distribuições a priori e a posteriori, que pode ser obtida por meio da divergência de Kullback-Leibler, dada por (ROBERT, 2007):

$$K_n(\pi) = \int \pi(\theta|x_{1:n}) \log \left( \frac{\pi(\theta|x_{1:n})}{\pi(\theta)} \right) d\theta \quad (23)$$

Sendo  $x_{1:n}$  as amostras  $(x_1, \dots, x_n)$ ;  $\pi(\theta|x_{1:n})$  a distribuição a posteriori; e  $\pi(\theta)$  a distribuição a priori.

A proposição de Bernardo e Berger, portanto, consiste em utilizar  $E[K_n(\pi)]$  como uma medida da informação ausente, na qual o valor esperado é calculado em relação à densidade marginal  $m(x_{1:n}) = \int p(x_{1:n}|\theta)\pi(\theta) d\theta$ . A priori de referência pode então ser determinada como sendo aquela que maximiza  $K_n(\pi)$  no limite quando o número de amostras tende ao infinito, ou seja:

$$K_n(\pi) = \lim_{n \rightarrow \infty} E[K_n(\pi)] \quad (24)$$

#### 2.2.1.1.4 Máxima entropia

Dado um espaço discreto e finito para os parâmetros ( $\Theta = \theta_1, \dots, \theta_n$ ) e assumindo-se  $\pi$  como a densidade de probabilidade de  $\theta$ , pode-se definir a entropia ( $\varepsilon(\pi)$ ) como

(BERGER, 2013):

$$\varepsilon(\pi) = - \sum_i \pi(\theta_i) \log(\pi(\theta_i)) \quad (25)$$

Considerando que há alguma informação parcial a priori sobre os parâmetros e que estas estejam especificadas na forma de restrições do tipo:

$$E^\pi [g_k(\theta)] = \sum_i \pi(\theta_i) g_k(\theta_i) = w_k \quad (26)$$

Sendo  $k = 1 \dots K$ .

A priori  $\pi$  que se busca é aquela que traz o mínimo de informação a respeito de  $\theta$ . Nesse contexto, isso significa dizer que a priori de interesse é aquela que maximiza a entropia e atende às restrições. Sua distribuição será dada por:

$$\pi(\theta_i) = \frac{\exp \left\{ \sum_{k=1}^K \lambda_k g_k(\theta_i) \right\}}{\sum_i \exp \left\{ \sum_{k=1}^K \lambda_k g_k(\theta_i) \right\}} \quad (27)$$

Sendo  $\lambda_k$  os multiplicadores de Lagrange obtidos a partir das restrições (Equação (26)).

Caso não haja restrições, a distribuição de máxima entropia será uniforme.

Para o caso contínuo, a entropia é dada por:

$$\varepsilon(\pi) = - \int \pi(\theta) \log \left( \frac{\pi(\theta)}{\pi_0(\theta)} \right) d\theta \quad (28)$$

Sendo  $\pi_0(\theta)$  a priori não-informativa de referência, que pode ser determinada por meio dos métodos descritos anteriormente.

De forma análoga ao caso discreto, a escolha da priori está sujeita às restrições, conforme a Equação (29) a seguir:

$$E^\pi [g_k(\theta)] = \int_{\Theta} \pi(\theta) g_k(\theta) d\theta = w_k \quad (29)$$

A priori de máxima entropia é obtida por:

$$\pi(\theta) = \frac{\exp \left\{ \sum_{k=1}^K \lambda_k g_k(\theta) \right\} \pi_0(\theta)}{\int_{\Theta} \exp \left\{ \sum_{k=1}^K \lambda_k g_k(\theta) \right\} \pi_0(\theta) d\theta} \quad (30)$$

### 2.2.1.1.5 Outras abordagens objetivas

As abordagens objetivas para obtenção das distribuições a priori não se restringem aos métodos mencionados nessa seção. São mencionadas e descritas na literatura diversas outras abordagens, como o método de Zellner (priori de máxima informação dos dados), o método de Rissanen, as prioris admissíveis, entre outras (BERGER et al., 2006; KASS; WASSERMAN, 1996).

### 2.2.1.2 Abordagem Subjetiva

A abordagem subjetiva (também denominada informativa) permite quantificar as convicções que um indivíduo tem a respeito de um determinado fenômeno e atribuí-las a distribuições de probabilidade. O desenvolvimento dessa teoria é atribuído a Ramsey, de Finetti e Savage, que trabalharam em sua formulação, a partir de uma série de axiomas. Ramsey e Finetti desenvolveram o conceito de probabilidade subjetiva baseada na escolha, enquanto Savage foi o responsável pela formalização dessa teoria (ELLSBERG, 2015; FISHBURN, 1986).

Entre os métodos descritos na literatura para estimação subjetiva das distribuições a priori destacam-se, a aproximação por meio de distribuições conhecidas e as aproximações não paramétricas (GARTHWAITE; KADANE; O'HAGAN, 2005; O'HAGAN et al., 2006).

#### 2.2.1.2.1 Aproximação por meio de distribuições conhecidas

Nesta abordagem assume-se que o conhecimento a priori pode ser descrito por meio de uma determinada família de distribuições de probabilidade. Nesse caso, faz-se necessária a determinação dos parâmetros dessas distribuições, conhecidos como hiperparâmetros, denominados dessa forma a fim de diferenciá-los dos parâmetros do modelo. Normalmente, a definição dos hiperparâmetros se dá com base em valores de momentos e quantis sobre os quais há um conhecimento prévio (WAKEFIELD, 2013).

Uma estratégia comumente utilizada é a escolha de distribuições a priori conjugadas. Uma família de distribuições a priori é denominada conjugada em relação a função de verossimilhança, se a distribuição a posteriori pertencer à mesma família da priori. A utilização de prioris conjugadas facilita a análise do modelo bayesiano, uma vez que a computação das distribuições a posteriori pode ser feita a partir da atualização dos hiperparâmetros, tendo em vista que ambas pertencem à mesma família. Além disso, em algumas aplicações, o uso de distribuições a priori conjugadas traz flexibilidade, uma vez que o conhecimento prévio (como a opinião de diferentes especialistas) é refletido na escolha dos hiperparâmetros. Assim, uma mesma distribuição pode ser usada na construção

de diversos modelos (O'HAGAN et al., 2006). Alguns exemplos de distribuições a priori conjugadas podem ser encontrados em Wakefield (2013).

Uma das principais críticas feitas a essa abordagem é que sua escolha se dá frequentemente pela conveniência matemática para o cálculo da posteriori. Isso compromete parcialmente o caráter subjetivo dessa abordagem pois, de certa forma, a informação a priori precisa ser alterada a fim de se adequar aos hiperparâmetros da família escolhida para a distribuição a priori (KRUSCHKE, 2014).

### 2.2.1.2.2 *Abordagens não paramétricas*

Nas abordagens paramétricas, assume-se que os parâmetros de interesse são finitos. Entretanto, a restrição ao número de parâmetros pode limitar as inferências que podem ser feitas a respeito de um determinado modelo, levando às inferências enviesadas (insatisfatórias). Por esse motivo, abordagens mais flexíveis tornaram-se necessárias, como é o caso da abordagem bayesiana não paramétrica (HJORT et al., 2010).

Este modelo considera que o espaço dos parâmetros é infinito e normalmente é utilizado quando a distribuição a priori não possui uma forma paramétrica. Além disso, esse tipo de abordagem torna-se necessária quando a dimensionalidade do problema é muito alta, por exemplo, em modelos nos quais o número de parâmetros cresce à medida que novas observações são feitas (MITRA; MÜLLER, 2015).

Consequentemente, o tratamento matemático para as abordagens não paramétricas é mais complexo, uma vez que há a necessidade de estimação de distribuições em um espaço infinito. Dentre os métodos para estimação, Mitra e Müller (2015) destacam os processos de Dirichlet, os processos Gaussianos e Poly Tree. Outras abordagens podem ser encontradas em Phadia (2015).

## 2.2.2 **Estimação das distribuições a posteriori**

A inferência bayesiana se dá na estimação dos parâmetros de interesse por meio da avaliação da distribuição a posteriori que, segundo a formulação de Bayes, é obtida pela multiplicação entre a função de verossimilhança e a distribuição a priori (ponderadas por uma constante de normalização). Entretanto, dependendo da formulação e da complexidade do problema (quantidade de parâmetros e tipos de distribuições utilizadas), a estimação da posteriori pode não ser trivial.

Uma das formas mais simples de se obter a distribuição a posteriori é por meio da utilização de distribuições a priori conjugadas com a função de verossimilhança (O'HAGAN et al., 2006). Nesses casos, pode-se determinar de forma exata a distribuição a posteriori por meio de demonstrações analíticas. Em alguns casos, a distribuição a priori estimada

é “forçada” para uma determinada família, justamente para viabilizar a conjugação e, conseqüentemente, simplificar os cálculos necessários para a estimação. Em contrapartida, a escolha da distribuição a priori mais conveniente do ponto de vista matemático pode distorcer o modelo proposto, uma vez que a informação prévia a respeito dos parâmetros deverá ser ajustada para se adequar aos hiperparâmetros da distribuição escolhida.

Quando as distribuições não são conjugadas ou a quantidade de parâmetros é elevada, podem surgir situações nas quais a demonstração analítica da posteriori já não é mais possível. Conseqüentemente, a determinação de informações relevantes na estimação dos parâmetros como média, variância, moda, mediana e quantis demanda o cálculo de integrais para as quais não há uma solução fechada. Nessas situações, pode-se recorrer a métodos assintóticos como a aproximação de Laplace ou de integração numérica para estimação das medidas de interesse, como a Quadratura Gauss-Hermite adaptativa (RUANAIDH; FITZGERALD, 2012). Entretanto, para problemas com dimensão maior que dez, essas alternativas apresentam relevantes problemas de precisão e custos computacionais elevados. Nesses casos, deve-se recorrer aos métodos de Monte Carlo via Cadeia de Markov (MCMC).

De forma sucinta, o método de Monte Carlo é uma designação dada para algoritmos computacionais baseados em amostragens aleatórias, que se valem da lei forte dos grandes números para estimar momentos de uma distribuição a partir da média de um elevado número de amostras, evitando, portanto, o cálculo de integrais (KROESE; TAIMRE; BOTEV, 2013).

Vale ressaltar que, para problemas multidimensionais, o método de Monte Carlo apresenta limitações para a obtenção dessas amostras. Para suplantar essa limitação, foram propostos métodos nos quais o processo de amostragem é feito de forma iterativa a partir de cadeias de Markov (CARLIN; LOUIS, 2008).

A combinação dessas duas abordagens (estimação por amostragem proposta pelo método de Monte Carlo e a obtenção de amostras por meio de cadeias de Markov) deu origem aos métodos MCMC. Dentre os algoritmos propostos, destacam-se o Metropolis-Hasting e o Amostrador de Gibbs (GAMERMAN; LOPES, 2006).

O advento dos métodos computacionais para determinação das distribuições a posteriori possibilitou a avaliação de modelos Bayesianos complexos, compostos por um elevado número de parâmetros e envolvendo distribuições não conjugadas. Por outro lado, o avanço proporcionado motivou o desenvolvimento de modelos cada vez mais elaborados ao ponto de nem mesmo os algoritmos MCMC serem capazes de encontrar soluções (GREEN et al., 2015).

Contudo, há ainda situações nas quais não é possível determinar a função de verossimilhança, ou seja, não há uma descrição matemática para ela. Essa situação é



problemática, pois essa função é necessária para a obtenção das distribuições a posteriori. Para lidar com esse tipo de modelo, surgiu, no final da década de 1990, uma classe de métodos denominada Computação Bayesiana Aproximada (do inglês *Approximate Bayesian Computation* - ABC) (GREEN et al., 2015; MARIN et al., 2012).

O principal propósito da ABC está na estimação da distribuição a posteriori sem o conhecimento da função de verossimilhança. A forma como isso é feito pode ser sintetizada nas seguintes ações: inicialmente, são gerados parâmetros a partir das distribuições a priori; em seguida, utilizam-se os parâmetros para simular dados a partir do modelo; o próximo passo consiste na comparação entre os dados gerados e os dados reais; se a distância entre eles estiver abaixo de um limiar pré-determinado, o valor do parâmetro é guardado; caso contrário, o parâmetro é descartado; esse procedimento é então repetido até se obter uma grande quantidade de valores para o parâmetro. A distribuição a posteriori é então determinada a partir dessa coletânea de estimativas.

É interessante observar que este procedimento pode ser utilizado junto com outros métodos, como Monte Carlo e MCMC, dando origem a uma série de algoritmos híbridos como ABC MCMC, ABC *Partial Rejection Control* (ABC PRC), ABC *Population Monte Carlo* (ABC PMC), ou ABC *Sequential Monte Carlo* (ABC SMC) (TURNER; ZANDT, 2012).

### 2.2.3 Estimação paramétrica a partir da posteriori

Conforme apresentado na seção 2.1.2, as hipóteses  $H1$ , tanto para SFT quanto para MSC, são parametrizadas pela RSR (equação 3 e equação 14, respectivamente). Como as medidas de desempenho associadas ao teste de hipóteses estão diretamente relacionadas a este parâmetro, é necessária sua estimação a partir dos registros ASSR que serão analisados. Usando o teorema de Bayes é possível relacionar o conhecimento a priori com a função de verossimilhança para fazer o levantamento da probabilidade a posteriori, da qual será feita a estimativa do parâmetro de interesse ( $\theta$ ). Essa relação é dada por Kay (1993):

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{p(x)} = \frac{p(x|\theta)p(\theta)}{\int p(x|\theta)p(\theta)d\theta} \quad (31)$$

Sendo  $p(\theta|x)$  a probabilidade a posteriori do parâmetro  $\theta$  a partir da amostra  $x$ ;  $p(x|\theta)$  a função de verossimilhança;  $p(\theta)$  a probabilidade a priori do parâmetro  $\theta$ ; e  $p(x)$  um fator de normalização para garantir que a posteriori integre em 1.

A formulação bayesiana para a estimação paramétrica envolve a atribuição de custos associados às diferentes estimativas que podem ser feitas acerca de  $\theta$ . Embora possa assumir uma formulação arbitrária, a literatura apresenta três tipos de função de custos

que se baseiam no erro entre a estimativa e o valor real do parâmetro (KAY, 1993). São elas:

- Erro quadrático:  $C(\theta, \hat{\theta}) = (\theta - \hat{\theta})^2$ ;
- Erro absoluto:  $C(\theta, \hat{\theta}) = |\theta - \hat{\theta}|$
- Função custo uniforme:  $C(\theta, \hat{\theta}) = \begin{cases} 1, & |\theta - \hat{\theta}| \geq \delta \\ 0, & |\theta - \hat{\theta}| < \delta \end{cases}; \quad \delta > 0$

$\hat{\theta}$  representa o valor estimado do parâmetro de interesse. O objetivo do estimador bayesiano está, portanto, em minimizar o valor esperado destes custos, cuja descrição matemática é dada por:

$$E [C(\theta, \hat{\theta})] = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\infty} C(\theta, \hat{\theta}) p(\theta|x) d\theta \right] p(x) dx \quad (32)$$

Demonstra-se que os estimadores  $\hat{\theta}$  que satisfazem essa condição para cada uma das três funções de custo apresentadas serão dados por (LEVY, 2008):

- Erro quadrático:  $\hat{\theta} = \int_{-\infty}^{\infty} \theta p(\theta|x) d\theta = E[\theta|x]$ ;
- Erro absoluto:  $\int_{-\infty}^{\hat{\theta}} p(\theta|x) d\theta = \int_{\hat{\theta}}^{\infty} p(\theta|x) d\theta$ ;
- Função custo uniforme:  $\hat{\theta} = \arg \max_{\theta} (p(\theta|x))$ .

Desta forma, tem-se que os estimadores  $\hat{\theta}$  para o erro quadrático, erro absoluto e função custo uniforme são, respectivamente, a média, a mediana e a moda da distribuição a posteriori. Em função destas relações apresentadas com a distribuição a posteriori, o estimador para o erro quadrático é denominado “Estimador de mínimo erro quadrático médio - MMSE”, enquanto o estimador a partir da função de custo uniforme recebe o nome de “Estimador de máximo a posteriori - MAP (*Maximum a posteriori*)”.

### 2.3 TESTE DE HIPÓTESES

O teste de hipóteses é um método estatístico utilizado pela teoria de detecção, que busca decidir entre dois ou mais modelos, aquele que é responsável pela geração dos dados observados. No contexto dos potenciais evocados auditivos em regime permanente, esse método é muito utilizado na verificação da presença ou ausência de respostas cerebrais, eliciadas pelos tons, no sinal de EEG.

Nesta seção são apresentadas duas abordagens utilizadas na realização dos testes de hipóteses. A primeira, baseada no teorema de Neyman e Pearson (NP), denominada abordagem clássica (ou frequentista). A segunda abordagem, denominada bayesiana, baseia-se no teorema de Bayes para estabelecer os critérios de decisão.

### 2.3.1 Abordagem Clássica

A abordagem clássica para o problema do teste de hipóteses teve grande disseminação com Ronald Aylmer Fisher, que formalizou a metodologia desse tipo de teste em seu livro “*Statistical Methods for Research Workers*” publicado em 1925. É importante ressaltar que o teste de Fisher envolve apenas uma hipótese, denominada nula, cuja distribuição é previamente conhecida sendo, portanto, formalmente denominado teste de significância.

O objetivo desse teste visa a comparar a medida de probabilidade de uma observação (valor de  $p$ ) em relação a um limiar denominado nível de significância (usualmente representado pela letra grega  $\alpha$ ). De um modo geral, utilizam-se níveis de significância de 5% ou 1%, entretanto, esse valor pode variar conforme a natureza do experimento. Além disso, a definição do nível de significância não precisa ser feita necessariamente a priori (GIGERENZER; KRAUSS; VITOUCH, 2004).

Assim, o valor de  $p$  é uma medida de probabilidade que indica a plausibilidade de ocorrência de valores iguais ou mais extremos que aquele observado. Portanto, se o valor de  $p$  for menor que o nível de significância, o resultado é considerado significativo, rejeitando-se, portanto, a hipótese nula. Além disso, a magnitude do valor de  $p$  tem um significado na interpretação do teste, ou seja, quanto menor for o seu valor, maior é a evidência contra a hipótese nula.

Ressalta-se que um resultado significativo apenas permite inferir que há evidências contra a hipótese nula, não sendo possível afirmar que uma hipótese alternativa seja verdadeira, afinal essa última sequer é considerada no teste de significância. Essa constatação foi uma das principais críticas de Neyman e Pearson (NP) à formulação de Fisher, servindo de motivação para o desenvolvimento de uma nova abordagem, na qual são consideradas duas hipóteses complementares.

Na abordagem de NP considera-se, portanto, uma hipótese principal (comumente denominada “nula” e representada por  $H_0$ ), sob a qual os dados são avaliados, e uma hipótese alternativa ( $H_1$ ), que é considerada como verdadeira quando se rejeita  $H_0$  (LEHMANN, 1993).

Uma consequência direta da inclusão de uma hipótese alternativa é a susceptibilidade a ocorrência de dois tipos de erro, denominados Tipo I e Tipo II. O erro Tipo I é aquele que mede a probabilidade ( $\alpha$ ) de rejeição da hipótese principal, quando ela é a hipótese verdadeira. Assim como no teste de significância, trabalha-se com  $\alpha = 5\%$  ou

$\alpha = 1\%$ . Embora o nível de significância (Fisher) e o erro Tipo I (NP) sejam normalmente representados pelo mesmo símbolo ( $\alpha$ ) e assumam valores na mesma faixa (5% ou 1%), há importantes distinções entre eles. No modelo de NP, o valor de  $\alpha$  é uma medida de erro definida a priori que estabelece um critério para aceitação de uma hipótese. Na abordagem de Fisher, esse parâmetro está associado à força de uma evidência contra a hipótese nula, podendo ser definido após a realização do experimento.

O outro erro (Tipo II) diz respeito à probabilidade ( $\beta$ ) de aceitação da hipótese principal quando a hipótese alternativa é a verdadeira. A partir de  $\beta$  é possível extrair outra importante medida, denominada poder do teste ( $1 - \beta$ ), que informa a probabilidade de rejeição da hipótese principal em favor da hipótese alternativa, ou seja, a probabilidade de se fazer uma correta aceitação da hipótese alternativa.

Os termos mencionados acima recebem uma nomenclatura distinta quando aplicados no contexto de detecção de sinais, campo no qual estão inseridos os potenciais evocados auditivos. Assim,  $\alpha$  é denominado probabilidade de falso alarme (PFA) ou falsos positivos,  $\beta$  é a taxa de perda (PM) ou falsos negativos e o poder do teste ( $1 - \beta$ ) é denominado probabilidade de detecção (PD).

O lema de Neyman e Pearson demonstra que, uma vez estabelecido o valor de ( $\alpha$ ), é possível determinar um limiar de decisão entre as duas hipóteses de modo a maximizar o poder do teste. Assim, deve-se decidir por  $H1$  quando (KAY, 1998):

$$L(x) = \frac{p(x; H1)}{p(x; H0)} > \gamma \quad (33)$$

Sendo  $p(x; H1)$  e  $p(x; H0)$  as funções de verossimilhança associadas às hipóteses  $H1$  e  $H0$ , respectivamente;  $\gamma$  o limiar de decisão para a razão de verossimilhança  $L(x)$ , que pode ser determinado a partir de  $\alpha$  com base na seguinte relação:

$$\int_{\{x:L(x)>\gamma\}} p(x; H0) dx = \alpha \quad (34)$$

Uma vez determinado o limiar  $\gamma$ , é possível encontrar o valor de  $x$  a partir do qual a relação  $L(x) > \gamma$  se torna verdadeira. Esse valor, definido como  $x_{crit\ NP}$ , delimitará as regiões de decisão para  $H0$  e  $H1$ . Desta forma, a equação 34 pode ser reescrita da seguinte forma:

$$PFA = \int_{x_{crit\ NP}}^{\infty} p(x; H0) dx = \alpha \quad (35)$$

Caso haja uma decisão por  $H1$ , é possível estimar o desempenho do detector, por meio do levantamento de PD, que é dado por:

$$PD = \int_{x_{crit NP}}^{\infty} p(x; H1) dx \quad (36)$$

A Figura 3 apresenta um exemplo de distribuições  $H0$  e  $H1$ , destacando o limiar de decisão, os erros tipo I e II e o poder do teste.




Figura 3 – Erros tipo I e II e Poder do teste.

Fonte: Dados da pesquisa.

A partir da Figura 3 observa-se que o limiar de separação entre as duas regiões de decisão é estabelecido a partir de  $\alpha$ . Se o dado observado for menor que o limiar, decide-se pela hipótese principal ( $H0$ ). Caso contrário, assume-se que a observação pertence à hipótese alternativa ( $H1$ ).

### 2.3.2 Abordagem Bayesiana

A formulação matemática da abordagem bayesiana no problema de detecção, assim como a NP, considera a existência de pelo menos duas hipóteses complementares para a decisão acerca de uma observação experimental. A principal diferença em relação à NP é que a abordagem bayesiana inclui no modelo a informação prévia sobre a probabilidade de ocorrência de cada uma das hipóteses, por meio de uma distribuição denominada a priori.

Além disso, a formulação bayesiana associa custos aos diferentes tipos de decisões que podem ser tomadas. No caso de um teste com duas hipóteses, há quatro possibilidades: decidir pela hipótese  $H0$  quando ela é, de fato, a verdadeira ( $P(H0|H0)$ ); decidir pela hipótese  $H0$  quando a hipótese  $H1$  é verdadeira ( $P(H0|H1)$ ); decidir por  $H1$  quando ela é verdadeira ( $P(H1|H1)$ ); e decidir por  $H1$  quando  $H0$  é verdadeira ( $P(H1|H0)$ ). Associando os custos a essas possíveis tomadas de decisão, tem-se a denominada função

risco de Bayes (R), que é apresentada a seguir (KAY, 1998):

$$\begin{aligned} R = & C_{00}P(H0|H0)P(H0) + C_{01}P(H0|H1)P(H1) \\ & + C_{11}P(H1|H1)P(H1) + C_{10}P(H1|H0)P(H0) \end{aligned} \quad (37)$$

Sendo  $P(H0)$  e  $P(H1)$  as probabilidades a priori para as hipóteses  $H0$  e  $H1$ , respectivamente; e  $C_{00}$ ,  $C_{01}$ ,  $C_{11}$  e  $C_{10}$  os custos associados a cada tipo de decisão ( $C_{ij}$  representa os custos associados à decisão pela hipótese  $i$ , quando a hipótese  $j$  é a verdadeira).

Na abordagem bayesiana, portanto, o limiar de decisão entre as duas hipóteses será determinado de modo a minimizar a função risco (diferentemente da abordagem de NP, que estabelece a priori um limite para o erro tipo I e busca maximizar o poder do teste).

Considerando que os custos associados às decisões erradas são maiores que aqueles associados a decisões corretas ( $C_{10} > C_{00}$  e  $C_{01} > C_{11}$ ), pode-se demonstrar (KAY, 1998) que o detector ótimo decidirá por  $H1$  quando:

$$L(x) = \frac{p(x|H1)}{p(x|H0)} > \frac{(C_{10} - C_{00})P(H0)}{(C_{01} - C_{11})P(H1)} = \tau \quad (38)$$

Sendo  $\tau$  o limiar de decisão.

Quando não são associados custos a decisões corretas ( $C_{00} = C_{11} = 0$ ) e as decisões erradas possuem o mesmo custo (por exemplo,  $C_{01} = C_{10} = 1$ ), a função risco passa a ser denominada de Probabilidade de Erro (PE), assumindo a seguinte formulação (KAY, 1998):

$$\begin{aligned} PE &= P(\{\text{decidir por } H0\} \wedge \{H1 \text{ verdadeiro}\}) \\ &\quad + P(\{\text{decidir por } H1\} \wedge \{H0 \text{ verdadeiro}\}) \\ PE &= P(H0, H1) + P(H1, H0) \\ PE &= P(H0|H1)P(H1) + P(H1|H0)P(H0) \end{aligned} \quad (39)$$

O detector ótimo nesse caso decide por  $H1$  quando:

$$L(x) = \frac{p(x|H1)}{p(x|H0)} > \frac{P(H0)}{P(H1)} = \tau \quad (40)$$

Para o detector bayesiano define-se  $x_{crit \text{ Bayes}}$  como sendo o menor valor de  $x$  que satisfaz  $L(x) > \tau$ , estabelecendo, portanto, o limite entre as regiões de decisão para  $H0$  e  $H1$ .

Ressalta-se que a Equação 39 pode ser descrita em função das probabilidades de detecção e de falso alarme, conforme apresentado a seguir (LEVY, 2008):

$$PE = (1 - PD)P(H1) + (PFA)P(H0) \quad (41)$$

Sendo  $PD = \int_{x_{crit\ Bayes}}^{\infty} p(x|H1)dx$ ; e  $PFA = \int_{x_{crit\ Bayes}}^{\infty} p(x|H0)dx$ .

Kay (1998) propõe uma outra forma de quantificar o desempenho do detector bayesiano, denominada de probabilidade de acerto (PA), que é definida como o complementar de PE, ou seja:

$$PA = 1 - PE \quad (42)$$

Se as probabilidades a priori para as hipóteses  $H0$  e  $H1$  forem consideradas iguais, então o detector com mínima probabilidade de erro será o de máxima verossimilhança:

$$L(x) = \frac{p(x|H1)}{p(x|H0)} > 1 \quad (43)$$

A Figura 4 ilustra esse detector, onde é possível observar que o limiar de decisão está localizado no ponto de interseção das distribuições  $p(x|H0)$  e  $p(x|H1)$ .

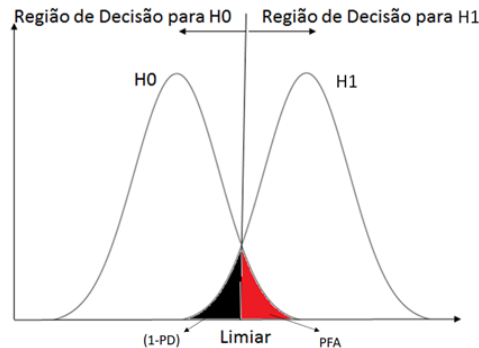


Figura 4 – Detector de máxima verossimilhança.

Fonte: Dados da pesquisa.

### 2.3.2.1 Detector bayesiano composto

A abordagem bayesiana pode ser aplicada também quando o(s) valor(es) do(s) parâmetro(s) das funções de verossimilhança condicionais para as hipóteses  $H0$  e/ou  $H1$  não é (são) explicitamente conhecido(s). Neste caso, assume-se que tais parâmetros são variáveis aleatórias e para elas são associadas funções de densidade de probabilidade

(fdp) que representam o conhecimento a priori. Desta forma, a razão entre as funções de verossimilhança de  $H1$  e  $H0$  será dada por (KAY, 1998):

$$L(x) = \frac{p(x|H1)}{p(x|H0)} = \frac{\int p(x|\theta_1; H1) p(\theta_1|H1) d\theta_1}{\int p(x|\theta_0; H0) p(\theta_0|H0) d\theta_0} \quad (44)$$

Sendo a fdp  $p(\theta_1|H1)$  o conhecimento a priori acerca de  $\theta_1$ , que parametriza  $p(x|H1)$ ; e  $p(\theta_0|H0)$  a fdp a priori de  $\theta_0$ , que parametriza  $p(x|H0)$ . Consequentemente, o detector descrito pela Equação 38 assumirá a seguinte formulação (LEVY, 2008):

$$L(x) = \frac{\int p(x|\theta_1; H1) p(\theta_1|H1) d\theta_1}{\int p(x|\theta_0; H0) p(\theta_0|H0) d\theta_0} > \frac{(C_{10} - C_{00}) P(H0)}{(C_{01} - C_{11}) P(H1)} = \tau \quad (45)$$

Em relação ao desempenho, a função de risco para este detector pode ser calculada da mesma forma como apresentado pela Equação 37.

### 2.3.3 Desempenho dos detectores

A avaliação de desempenho de detectores pode ser realizada por meio de um gráfico denominado *Receiver Operating Characteristics* (ROC) que relaciona a probabilidade de detecção em função da probabilidade de falsos alarmes. É importante destacar que este gráfico pode ser utilizado para análises de desempenho tanto da abordagem NP, quanto da bayesiana.

Pode-se demonstrar que a inclinação da reta tangente à curva ROC é igual ao limiar do detector ( $\tau$ ) para aquele ponto de operação ( $PD(\tau), PFA(\tau)$ ), ou seja (CANDY, 2016):

$$\tau = \frac{dPD(\tau)}{dPFA(\tau)} \quad (46)$$

A Figura 5 apresenta a curva ROC e sua relação com o limiar de decisão.

Nota-se, portanto, que o detector ideal é aquele que opera com a probabilidade de falsos alarmes nula e probabilidade de detecção é máxima, ou seja, no ponto (0,1).

#### 2.3.3.1 Critério Minimax

Conforme apresentado anteriormente, a construção de um detector bayesiano envolve a atribuição de custos e de probabilidades a priori para as hipóteses concorrentes. Quando não há conhecimento suficiente acerca do fenômeno observado que possibilite estabelecer tais probabilidades a priori, pode-se recorrer à implementação de um teste que






Figura 5 – Curva ROC e limiar de decisão.

Fonte: Elaborado pelo autor.

busque minimizar a função risco de Bayes considerando a escolha menos favorável para tais probabilidades, ou seja, aqueles valores de  $P(H_0)$  e  $P(H_1)$  que maximizarão a Equação 37.

Demonstra-se que os pontos de operação ( $PD$ ,  $PFA$ ) com máxima função de risco serão regidos pela seguinte relação (LEVY, 2008):

$$C_{11} - C_{00} + (C_{01} - C_{11})(1 - PD) - (C_{10} - C_{00})(PFA) = 0 \quad (47)$$

Considerando  $C_{00} = C_{11}$  e  $C_{01} = C_{10}$ , obtém-se:

$$PD = 1 - PFA \quad (48)$$

A equação 48 está representada graficamente na Figura 5 pela reta pontilhada.

Desta forma, o ponto de intersecção da reta  $PD = 1 - PFA$  com a curva ROC representa o limiar de decisão ( $\tau$ ) para o qual a função de risco é máxima (consequentemente, resultando na probabilidade de erro máxima).

Para determinar os valores das probabilidades a priori associadas a esse ponto de operação, basta aplicar a relação estabelecida na equação 40, ou seja:

$$\tau = \frac{P(H_0)}{P(H_1)} = \frac{P(H_0)}{1 - P(H_0)} \quad (49)$$

Logo,

$$P(H_0) = \frac{\tau}{1 + \tau} \quad (50)$$

## 3 MATERIAIS E MÉTODOS

A fim de atingir os objetivos propostos no Capítulo 1, o desenvolvimento deste trabalho foi dividido em três etapas. Inicialmente foram realizadas simulações para verificar o desempenho dos detectores e, em seguida, foram avaliados estimadores para diferentes RSR. Por fim, os algoritmos desenvolvidos foram aplicados em dados reais.

A primeira etapa (seção 3.1) consiste no levantamento das curvas teóricas de desempenho dos detectores NP e bayesiano para o SFT e MSC. Nesta etapa, também foram realizadas simulações de Monte Carlo para comparação com os desempenhos teóricos esperados.

Conforme apresentado na seção 2.1.2, o desempenho dos detectores está diretamente relacionado à RSR presente nos sinais analisados. Contudo, no caso de registros reais de EEG, essa informação é desconhecida, sendo, portanto, necessária a aplicação de técnicas que possibilitem a sua estimação. Desta maneira, a segunda etapa do desenvolvimento deste trabalho foi dedicada à estimação da RSR (seção 3.2). Para isso, foram realizadas simulações envolvendo duas abordagens distintas. Na primeira abordagem, a estimação foi realizada com base na inferência bayesiana, enquanto na segunda tratou-se da estimação da RSR a partir das equações 7 e 15, que relacionam em forma fechada esse parâmetro às amostras dos testes SFT e MSC, respectivamente.

Por fim (seção 3.3), após a definição do método de estimação da RSR mais apropriado, passou-se para a terceira etapa, que consistiu na aplicação dos algoritmos implementados em uma base de dados contendo potenciais evocados auditivos reais. Os códigos foram desenvolvidos utilizando-se o software MATLAB e todo o processamento foi realizado de forma *offline*.

### 3.1 DESEMPENHO DOS DETECTORES

#### 3.1.1 Desempenho teórico

A seguir são descritos os procedimentos utilizados no levantamento das curvas de desempenho dos detectores NP e bayesiano, a partir das equações teóricas.

### 3.1.1.1 Detector NP

O levantamento do desempenho teórico dos detectores a partir da abordagem clássica foi realizado com base na equação 36. Visando um levantamento abrangente acerca do desempenho do detector NP para SFT, o cálculo de PFA e PD foi realizado considerando a seguinte faixa de variação dos parâmetros envolvidos:  $0 < \alpha < 1$ ;  $-30 \leq RSR_{dB} \leq 20$  e  $M = [4, 12, 16, 32, 48, 64, 96]$ , na qual  $RSR_{dB}$  representa a RSR em decibéis e  $M$  o número de componentes de frequências vizinhas à frequência considerada como tendo resposta.

De forma análoga, foi realizado o levantamento do detector NP para a MSC. A faixa de variação dos parâmetros foi semelhante àquela utilizada na SFT, ou seja:  $0 < \alpha < 1$ ;  $-30 \leq RSR_{dB} \leq 20$  e  $N = [4, 12, 16, 32, 48, 64, 96]$ , sendo  $N$  é o número de janelas.

### 3.1.1.2 Detector Bayesiano

Para o levantamento da performance teórica do detector bayesiano consideraram-se os custos da função de risco como sendo  $C_{00} = C_{11} = 0$  e  $C_{01} = C_{10} = 1$ . Considerando que  $P(H1) + P(H0) = 1$ , as probabilidades de erro dos detectores para SFT e MSC foram calculadas a partir da equação 41.

A variação dos parâmetros envolvidos nos cálculos do desempenho do detector bayesiano seguiu o mesmo procedimento adotado para o detector NP, ou seja:  $-30 \leq RSR_{dB} \leq 20$  e  $M = N = [4, 12, 16, 32, 48, 64, 96]$ . Entretanto, para o detector bayesiano, é necessário especificar valores para  $P(H0)$ . Desta forma, foi realizada uma análise de sensibilidade dos valores de PE considerando-se  $0 < P(H0) < 1$ .

## 3.1.2 Desempenho por simulações

Na simulação foram gerados sinais para representar os registros dos potenciais evocados auditivos, cuja composição foi dada pela sobreposição de um tom puro de 78,12 Hz e um ruído gaussiano de média zero e variância unitária, ambos com duração de 4,096 s. Considerou-se uma frequência de amostragem ( $f_s$ ) de 1 kHz, resultando em 4.096 pontos por registro. A amplitude do sinal senoidal foi ajustada para que se pudesse obter os diferentes valores de RSR desejados.

O procedimento de geração de um registro foi então repetido cem vezes ( $R=100$ ) a fim de se obter um conjunto de dados que mimetizasse uma sessão completa de estimulação, assim como foi feito na aquisição do banco de dados de potenciais evocados auditivos realizada por Souza (2011).

O procedimento de geração dessa matriz de registros (100 x 4.096) foi então

repetido diversas vezes ( $K = 10.000$ ) para viabilizar a simulação de Monte Carlo. Para aplicação dos detectores, os dados simulados foram convertidos para o domínio da frequência utilizando a transformada rápida de Fourier (*Fast Fourier Transform* - FFT), calculada com 4.096 pontos.

Conforme apresentado anteriormente, as amostras para SFT foram obtidas por meio da Equação 1 ( $\hat{\phi}(f_0) = \frac{|X(f_0)|^2}{\frac{1}{M} \sum_{i=1}^M |X(f_i)|^2}$ ), na qual  $f_0$  é a componente espectral de interesse.

Para a estimação do ruído ( $\frac{1}{M} \sum_{i=1}^M |X(f_i)|^2$ ), foram considerados os diferentes valores de  $M$  estipulados na seção 3.1.1 para a seleção das componentes espectrais adjacentes à  $f_0$ .

Em relação à MSC, as amostras foram obtidas por meio da equação 13 ( $\hat{k}^2(f_0) = \frac{\left| \sum_{i=1}^N Y_i(f_0) \right|^2}{N \sum_{i=1}^N |Y_i(f_0)|^2}$ ), na qual  $f_0$  também representa a componente espectral de interesse e  $N$  é o número de registros (janelas) utilizados na estimação.

Para o levantamento do desempenho dos detectores para SFT e MSC, foram necessárias simulações de duas situações distintas: sem resposta e com resposta. No cenário em que há respostas evocadas, as equações 1 e 13 foram calculadas considerando  $f_0 = 78,12$  Hz, que é a componente espectral presente no sinal senoidal simulado. Já para o cenário sem resposta evocada, os cálculos de  $\hat{\phi}(f_0)$  e  $\hat{k}^2(f_0)$  foram realizados considerando como bin de interesse ( $f_0$ ) uma componente espectral onde houvesse apenas a manifestação de ruído. Neste caso, as equações 1 e 13 foram então calculadas para a componente  $f_0 = 107,42$  Hz. Os números decimais associados aos bins de interesse ( $f_0 = 78,12$  Hz - com resposta e  $f_0 = 107,42$  Hz - sem resposta) se devem ao ajuste realizado em  $f_0$  de modo a garantir um número inteiro de oscilações em cada registro.

Esse procedimento viabilizou o levantamento de conjuntos de amostras para as hipóteses  $H1$  de SFT e MSC (quando  $f_0 = 78,12$  Hz) e outro conjunto contendo amostras para as hipóteses  $H0$  (quando  $f_0 = 107,42$  Hz). A partir desses grupos de amostras foi possível estimar a probabilidade de detecção e a probabilidade de falso alarme. No caso das PD, contabilizou-se o percentual de amostras de  $H1$  cujos valores eram maiores que os respectivos valores críticos de interesse ( $\phi_{crit NP}$ ,  $\phi_{crit Bayes}$ ,  $k^2_{crit NP}$ ,  $k^2_{crit Bayes}$ ). Para as PFA, a contabilização em relação a esses valores críticos foi feita considerando as amostras de  $H0$ .

De posse de PD e PFA, foram estimadas as probabilidades de erro do detector bayesiano para SFT e MSC ( $PE_{SFT}$  e  $PE_{MSC}$ ).

## 3.2 ESTIMAÇÃO DA RSR

### 3.2.1 Estimação Bayesiana

Foram realizadas simulações visando a estimação da RSR a partir das amostras geradas para os testes SFT ( $\hat{\phi}(f_0)$ ) e MSC ( $\hat{k}^2(f_0)$ ). De maneira análoga ao procedimento descrito na seção anterior (3.1.2), o estudo dos estimadores bayesianos considerou os dois cenários analisados (com e sem resposta) a fim de se levantar as performances dos estimadores quando  $RSR > 0$  e  $RSR = 0$ , respectivamente. Para o primeiro cenário foi considerado um sinal com  $RSR = 1$  ( $RSR_{dB} = 0$  dB).

Conforme descrito na equação 18, o cálculo da fdp a posteriori (da qual será estimado o parâmetro de interesse) envolve uma fdp a priori para a RSR, ou seja,  $P(RSR)$ . Como a escolha de  $P(RSR)$  é arbitrária, foram consideradas cinco distribuições distintas para verificar a influência que a informação a priori tem no desempenho dos estimadores.

Desta forma, foram escolhidas as seguintes fdp para  $P(RSR)$ :

1. Distribuição Normal, com média igual ao valor real da RSR analisada e variância pequena;
2. Distribuição Normal, com média igual ao valor real da RSR analisada e variância grande;
3. Distribuição Normal, com média distante em relação ao valor real da RSR analisada e variância pequena;
4. Distribuição Normal, com média distante em relação ao valor real da RSR analisada e variância grande;
5. Distribuição Uniforme cobrindo um intervalo amplo.

A Tabela 1 sintetiza as distribuições a priori utilizadas em cada cenário analisado.

Tabela 1 – Probabilidades a priori [ $P(RSR)$ ] utilizadas nas simulações dos estimadores bayesianos para os cenários com e sem respostas.

Tipo de priori	Com resposta (RSR=1)	Sem resposta (RSR=0)
1	$N(\mu = RSR = 1; \sigma^2 = 0.001)$	$N(\mu = RSR = 0; \sigma^2 = 0.001)$
2	$N(\mu = RSR = 1; \sigma^2 = 1)$	$N(\mu = RSR = 0; \sigma^2 = 1)$
3	$N(\mu = 1, 5; \sigma^2 = 0.001)$	$N(\mu = 0, 5; \sigma^2 = 0.001)$
4	$N(\mu = 1, 5; \sigma^2 = 1)$	$N(\mu = 0, 5; \sigma^2 = 1)$
5	$U(0, 100)$	$U(0, 100)$

Fonte: Dados de pesquisa

O propósito destas escolhas está em simular algumas situações que podem ser consideradas ao se utilizar a inferência bayesiana. As distribuições normais representam

escolhas subjetivas para as distribuições a priori de RSR (vide seção 2.2.1.2). Aquelas com variância pequena, por exemplo, representam cenários nos quais existe grande convicção a respeito do parâmetro de interesse. Assim, nas distribuições apresentadas na primeira linha da tabela 1 -  $N(\mu = RSR = 1; \sigma^2 = 0.001)$  para  $RSR > 0$  e  $N(\mu = RSR = 0; \sigma^2 = 0.001)$  para  $RSR = 0$  - o valor esperado é igual ao valor real do parâmetro. Já para as duas distribuições que constam na terceira linha da tabela 1 -  $N(\mu = RSR = 1,5; \sigma^2 = 0.001)$  para  $RSR > 0$  e  $N(\mu = RSR = 0,5; \sigma^2 = 0.001)$  para  $RSR = 0$  - o valor esperado assumido está distante do valor real, representando, portanto, um erro de suposição inicial. A probabilidade a priori uniforme, por sua vez, reflete a condição na qual não se tem, ou não se deseja considerar qualquer informação prévia sobre o parâmetro (priori não-informativa, vide seção 2.2.1.1).

A partir destas fdp a priori, foram calculadas as respectivas distribuições a posteriori, para então serem extraídas as estimativas acerca da RSR. Conforme apresentado anteriormente, essa estimativa dependerá da função de custo adotada.

Neste trabalho foi investigada a estimação a partir da função de custo uniforme, ou seja, a RSR foi calculada a partir da moda das distribuições a posteriori (MAP). A escolha pelo MAP se deve, principalmente, pelo fato de não ser necessário o cálculo de integrais para o levantamento da RSR, como ocorre para os outros dois estimadores (MMSE e Erro Absoluto).

Para fins de comparação, após o cálculo dos estimadores bayesianos para a RSR, foi realizada também a implementação do estimador de máxima verossimilhança (do inglês, *Maximum Likelihood Estimation* - MLE) (KAY, 1993) para  $RSR > 0$  e  $RSR = 0$ . Este procedimento teve como propósito possibilitar uma comparação do desempenho dos estimadores bayesianos em relação ao estimador comumente utilizado na abordagem clássica (na qual o parâmetro desconhecido não é considerado uma variável aleatória e, portanto, não se assume probabilidades a priori para ele).

A fim de se verificar o comportamento assintótico dos estimadores, as simulações foram realizadas considerando-se janelas temporais mais extensas, totalizando 300 registros de 4,096 s.

### 3.2.2 Estimação Analítica

A estimação de parâmetros baseada na inferência bayesiana se dá por meio das funções de verossimilhança condicionais e das probabilidades a priori. Contudo, para os testes SFT e MSC, há expressões analíticas que possibilitam estimar a RSR a partir das amostras coletadas, como mostrado pelas equações 7 e 15, respectivamente.

Desta forma, a RSR foi estimada também por meio da análise dessas equações. Posteriormente, os resultados encontrados foram comparados em relação aos estimadores

bayesianos e MLE.

Para a SFT, o estimador analítico é dado por:

$$\widehat{RSR} = \left( \frac{M-1}{M} \cdot \frac{\sum_{r=1}^R \hat{\phi}_r(f_0)}{R} \right) - 1 \quad (51)$$

Sendo  $R$  o total de amostras analisadas; e  $\hat{\phi}_r(f_0)$  a  $r$ -ésima amostra obtida.

Já para a MSC, foi utilizada a equação 15, que é transcrita a seguir:  $\widehat{RSR} = \frac{\hat{k}^2(f_0)}{1-\hat{k}^2(f_0)}$ ; sendo  $\hat{k}_r^2(f_0)$  a  $r$ -ésima amostra calculada.

### 3.3 APLICAÇÃO EM DADOS REAIS

Os detectores implementados foram aplicados em uma base de dados contendo registros ASSR de nove indivíduos normo-ouvintes previamente avaliados por otoscopia e audiometria tonal (aprovado pelo Comitê de Ética em pesquisa da Universidade Federal de Minas Gerais - UFMG, sob o número 0369.0.203.000-10), sem perdas auditivas, submetidos à estimulação binaural múltipla utilizando tons de amplitude modulada (AM), apresentados via fone de inserção E-A-RTone 5A da seguinte forma (SOUZA, 2011):

- Orelha esquerda: tons com portadora de 500 Hz, 1.000 Hz, 2.000 Hz e 4.000 Hz modulados, respectivamente, a 80,08 Hz; 84,96 Hz; 89,84 Hz e 94,73 Hz;
- Orelha direita: tons com portadora de 500 Hz, 1.000 Hz, 2.000 Hz e 4.000 Hz modulados, respectivamente, a 78,12 Hz; 83,00 Hz; 86,91 Hz e 91,79 Hz.

Cada indivíduo foi estimulado com intensidades de 50 dB<sub>SPL</sub>; 40 dB<sub>SPL</sub>; 30 dB<sub>SPL</sub> e 20 dB<sub>SPL</sub>.

Os dados coletados (derivação Cz-inion) foram submetidos a um algoritmo para a remoção de artefatos (TIERRA-CRIOLLO, 2001) e posteriormente organizados em matrizes, contendo, para cada intensidade, 100 registros de respostas evocadas com duração de 4,096 segundos ( $fs = 1$  kHz; 4.096 pontos por registro). Os registros foram convertidos para o domínio da frequência utilizando a FFT, calculada com 4.096 pontos.

Os resultados aqui apresentados se referem à aplicação dos detectores na avaliação da resposta à portadora de 500 Hz da orelha direita  $f_0 = 78,12$  Hz. Para avaliar a performance de ambos os detectores na ausência de respostas evocadas, foi realizado um experimento de controle negativo ( $SNR_{dB} \rightarrow -\infty$ ). Neste caso, analisou-se a componente espectral  $f_0 = 107,42$  Hz, contendo apenas ruído.

Para a execução de SFT, utilizaram-se  $M = 16$  componentes espectrais para a estimação do ruído. Além disso, deve ser salientado que, a cada iteração, o sinal considerado

na análise era o resultado da promediação temporal de todos os registros previamente analisados. Essa estratégia visou promover a elevação da RSR e, conseqüentemente, melhorar o desempenho dos detectores para SFT.

Para a MSC, o janelamento do sinal foi realizado tomando-se sequencialmente os registros disponíveis até o limite máximo de  $N = 100$ .

A estimação da RSR para o levantamento das curvas de performance (PD e PE) para SFT e MSC foi realizada com base no método de estimação que apresentou o melhor desempenho nas simulações.

No caso do detector bayesiano, para o levantamento de PE, foi necessário ainda definir um critério de escolha para as probabilidades a priori das duas hipóteses. Os valores de  $P(H0)$  foram definidos seguindo duas estratégias: a primeira considerou  $P(H0) = 0,5$  ao longo de todo o processamento, enquanto a segunda considerou o menor valor possível para  $P(H0)$  baseado na estimativa da RSR encontrada na iteração anterior. A seguir são apresentados os pseudocódigos que descrevem os algoritmos desenvolvidos para o cálculo de PE para a primeira estratégia (Algoritmo 1: Calcular PE para  $P(H0)=0,5$ ) e para a segunda estratégia (Algoritmo 2: Calcular PE para “ $P(H0)$  min”):

---

**Algoritmo 1:** Calcular PE para  $P(H0) = 0,5$

---

```

1 num_amostras ← 1;
2  $P(H0) \leftarrow 0,5$ ;
3 while num_amostras ≤ 100 do
4   | Calcular amostra;
5   | Estimar RSR;
6   | Calcular PE dado  $P(H0)=0,5$ ;
7   | num_amostras ← num_amostras + 1;
8 end
```

---



---

**Algoritmo 2:** Calcular PE para “ $P(H0)$  min”

---

```

1 num_amostras ← 1;
2  $P(H0) \leftarrow 0,5$ ;
3 while num_amostras ≤ 100 do
4   | Calcular amostra;
5   | Estimar RSR;
6   | Calcular PE dado  $P(H0)$ ;
7   | Identificar “ $P(H0)$  min”;
8   |  $P(H0) \leftarrow$  “ $P(H0)$  min””;
9   | num_amostras ← num_amostras + 1;
10 end
```

---



Para ambas as estratégias se assumiu que os custos associados às decisões corretas (verdadeiros negativos e verdadeiros positivos) seriam nulos ( $C_{00} = C_{11} = 0$ ) e que os custos associados às decisões erradas (falsos positivos - erro tipo I e falsos negativos - erro tipo II) teriam o mesmo valor ( $C_{10} = C_{01} = 1$ ).

## 4 RESULTADOS

Neste capítulo são apresentados os resultados alcançados no desenvolvimento desta tese. Inicialmente (seção 4.1) são apresentadas as curvas de desempenho (teórica e simulação) dos detectores NP e bayesiano para SFT e MSC. Em seguida, foi feita uma breve análise dos resultados, visando a estabelecer paralelos entre o desempenho dos dois detectores (NP vs. bayesiano) e entre as performances das duas técnicas ORD analisadas (SFT vs. MSC). A seção 4.2 traz os resultados encontrados no estudo acerca dos estimadores para a RSR. Na primeira parte desta seção, são apresentados os resultados da aplicação dos estimadores (bayesiano e por expressões fechadas) para SFT. Em seguida, são apresentados os achados para MSC. Por fim, na seção 4.3 são apresentados os resultados referentes à aplicação dos detectores nos registros de ASSR a partir do estimador que apresentou o melhor desempenho.

### 4.1 DESEMPENHO DOS DETECTORES

#### 4.1.1 Teste SFT

A seguir são apresentados os resultados referentes à aplicação dos detectores NP e bayesiano ao teste SFT.

##### 4.1.1.1 Detector NP

A Figura 6 e a Figura 7 apresentam as curvas ROC do detector NP aplicado a SFT para os diversos valores considerados para  $M$  (número de bins vizinhos a  $f_0$  utilizados na estimação do ruído). A Figura 6 traz os resultados para  $M=4, 12$  e  $16$ , enquanto que na Figura 7 estão os achados para  $M=32, 48, 64$  e  $96$ . As curvas teóricas e aquelas obtidas na simulação estão indicadas pelas linhas sólidas e tracejadas, respectivamente.




Figura 6 – Curvas ROC do detector NP aplicado ao SFT para diversos valores de  $M$  analisados. Nas legendas estão indicados os valores de RSR (em dB) considerados. Os desempenhos teórico e de simulação são apresentados pelas linhas sólidas e tracejadas, respectivamente: (a)  $M=4$ ; (b)  $M=12$ ; (c)  $M=16$ .

Fonte: Dados da pesquisa.

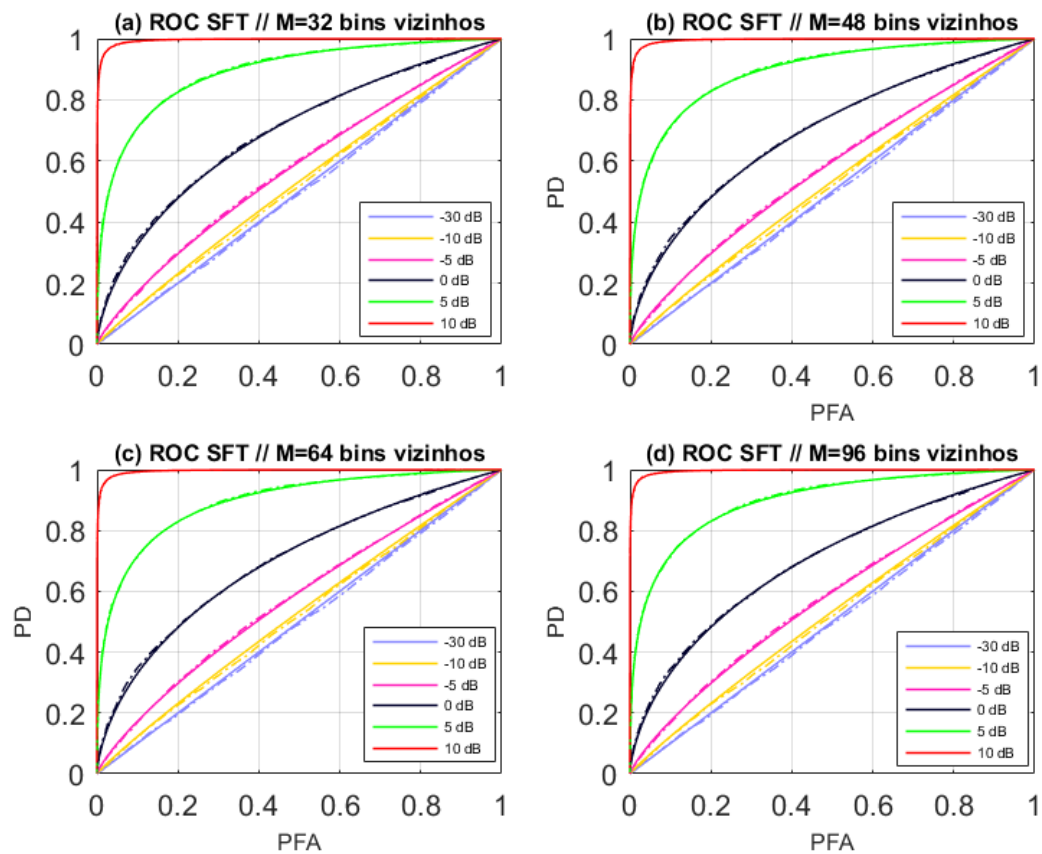


Figura 7 – Curvas ROC do detector NP aplicado ao SFT para diversos valores de  $M$  analisados. Nas legendas estão indicados os valores de RSR (em dB) considerados. Os desempenhos teórico e de simulação são apresentados pelas linhas sólidas e tracejadas, respectivamente: (a)  $M=32$ ; (b)  $M=48$ ; (c)  $M=64$  e (d)  $M=96$ .

Fonte: Dados da pesquisa.

As curvas ROC permitem constatar que o desempenho alcançado nas simulações foi muito próximo ao comportamento teórico e que o detector tende ao ponto de operação ótimo ( $PFA = 0$ ;  $PD = 1$ ) quanto maior for a RSR, independentemente do valor de  $M$  considerado. Em relação à quantidade de bins utilizados na estimação do ruído, pode-se observar que não há uma melhora expressiva no desempenho de SFT a partir de  $M = 12$ . Esta constatação fica mais evidente quando as curvas de desempenho obtidas na simulação são sobrepostas, conforme apresentado na Figura 8. Para facilitar a visualização foram considerados apenas os resultados para  $PFA = 0,05$ .

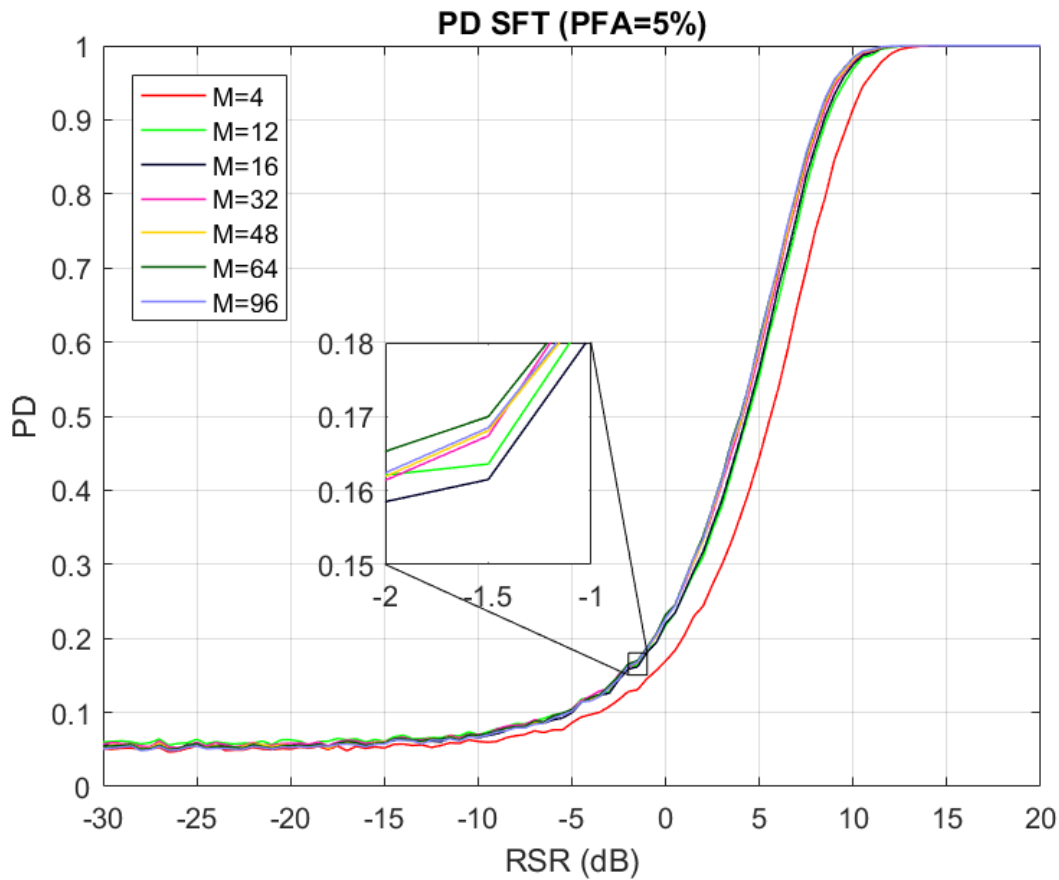


Figura 8 – Curvas PD do detector NP aplicado ao SFT em função da RSR (em dB) para os diversos valores de  $M$  analisados (vide legenda), considerando  $PFA=0,05$ . As curvas representam os achados das simulações.

Fonte: Dados da pesquisa.

Na Figura 9 é dado destaque para o detector NP considerando  $PFA = 5\%$  e  $M = 16$ , que representam as mesmas condições nas quais foram analisados os registros ASSR. Na Figura 9 (a) são apresentados: o valor esperado para  $\phi(f_0)$  e o valor crítico ( $\phi_{crit\ NP}$ ), ambos em função da RSR. A Figura 9 (b) apresenta o desempenho do detector (PD) obtido nas simulações sobreposto à curva teórica esperada.

Nota-se pelo gráfico “(a)”, que o valor de  $\phi(f_0)$  cresce à medida que a RSR aumenta. Para valores de RSR inferiores a, aproximadamente, 3,5 dB tem-se que  $\phi(f_0) < \phi_{crit\ NP}$ , o que leva o detector a decidir por  $H_0$ . A partir de  $RSR \approx 3,5$  dB, percebe-se que  $\phi(f_0)$  ultrapassa o limiar de decisão, o que leva à rejeição da hipótese nula. Para esses valores estão indicados os respectivos intervalos de confiança, que foram determinados a partir dos quantis 2,5% e 97,5% das amostras geradas para  $H_1$ . É possível observar que para  $3,5\text{ dB} < RSR < 10\text{ dB}$  a hipótese  $H_0$  é rejeitada, porém o intervalo de confiança (95%) de  $\phi(f_0)$  compreende valores que estão abaixo do limiar. Essa parcela corresponde à taxa de falsos negativos ( $\beta$ ) associada ao detector. Por outro lado, para  $RSR > 10$  dB, percebe-se que os limites inferiores dos intervalos de confiança já se encontram acima do limiar de

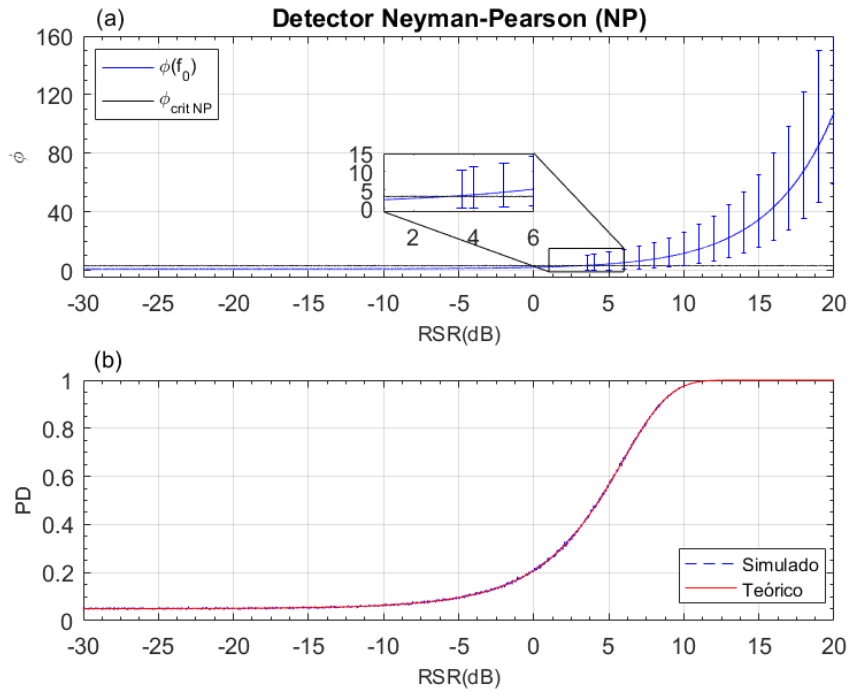


Figura 9 – Desempenho do detector NP em função da RSR para SFT ( $M = 16$ ): (a) Relação entre  $\phi(f_0)$  (linha azul) e o limiar de decisão ( $\phi_{crit\ NP}$ ) considerando uma probabilidade de falso alarme de 5% (linha horizontal preta), com indicação do intervalo de confiança de 95% (linhas azuis verticais). A região ampliada destaca o ponto onde  $\phi(f_0)$  ultrapassa  $\phi_{crit\ NP}$ ; (b) Probabilidade de detecção (PD) obtida pelo levantamento teórico (vermelho sólido) e por simulação (azul tracejado).

Fonte: Dados da pesquisa.

decisão. Essa relação entre os intervalos de confiança e a taxa de falsos negativos fica mais nítida analisando-se o gráfico “(b)” da Figura 9, haja vista que  $PD = 1 - \beta$ .

Pode-se perceber que o primeiro ponto em que houve detecção ( $RSR \approx 3,5$  dB) é aquele que apresenta a maior parcela do intervalo de confiança abaixo do limiar. Nesse ponto, tem-se, aproximadamente,  $PD=46\%$ . À medida que a RSR aumenta, os limites inferiores dos intervalos de confiança vão se aproximando do limiar e, conseqüentemente, o valor de PD vai se elevando, até chegar, aproximadamente, em 100% para  $RSR > 10$  dB.

#### 4.1.1.2 Detector Bayesiano

As Figuras 10 a 13 apresentam os mapas de contorno (teórico e simulado) que descrevem a probabilidade de erro, PE, em função da RSR e da probabilidade a priori (descrita em termos de  $P(H_0)$ ). Os valores de PE associados a cada curva de contorno estão indicados pelos números assinalados no interior das figuras ( $0,001 \leq PE \leq 0,50$ ) e pela barra de cores localizada à direita.

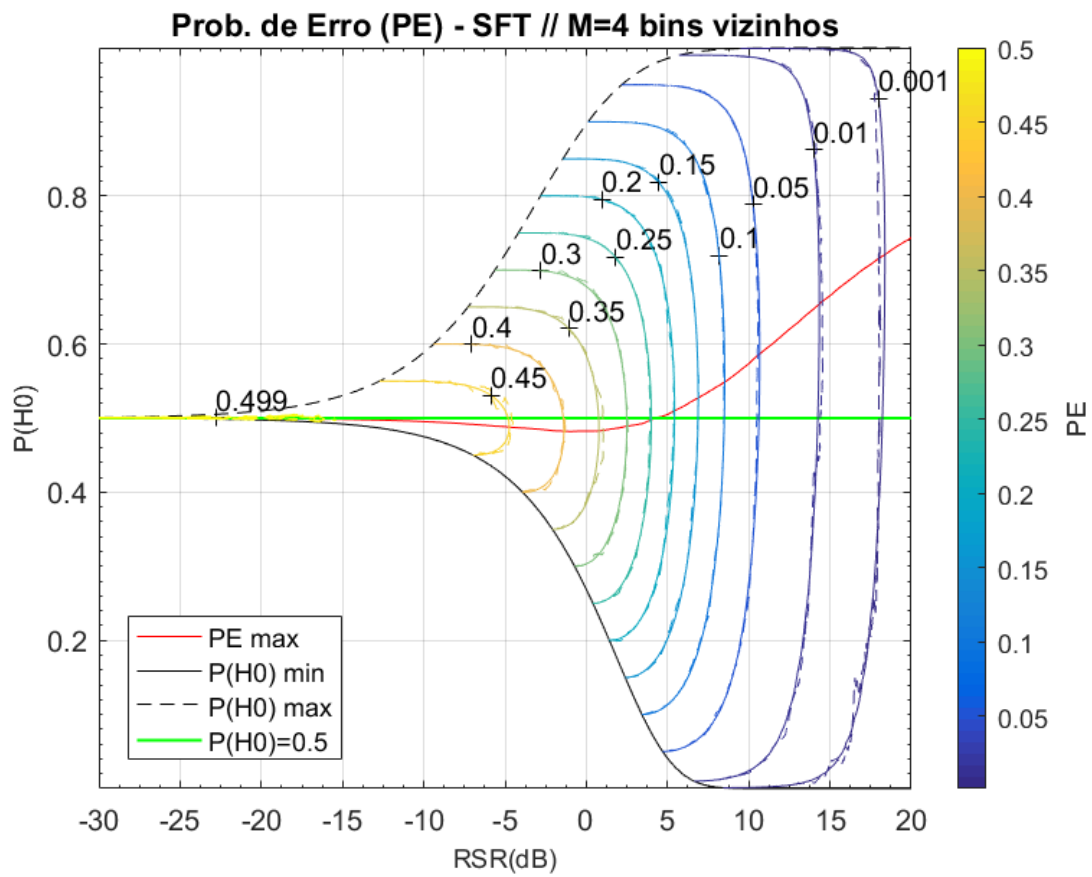


Figura 10 – Desempenho do detector bayesiano para SFT (teórico – curvas de contorno em linha sólida; simulado – curvas de contorno em linha tracejada) em função da RSR e  $P(H_0)$ , para  $M = 4$ . Os valores de PE estão indicados sobre cada linha de contorno (+) e pela barra de cores à direita. As curvas indicadas na legenda representam quatro estratégias distintas utilizadas na escolha de  $P(H_0)$ : “PE max”(vermelho sólido), “ $P(H_0)$  min” (preto sólido), “ $P(H_0)$  max” (preto tracejado) e “ $P(H_0) = 0,5$ ” (verde sólido).

Fonte: Dados da pesquisa.




Figura 11 – Desempenho do detector bayesiano para SFT: (a)  $M = 12$ ; (b)  $M = 16$  (com destaque para a interseção das curvas de contorno em  $RSR = 0$  dB [linha vertical preta pontilhada]).

Fonte: Dados da pesquisa.

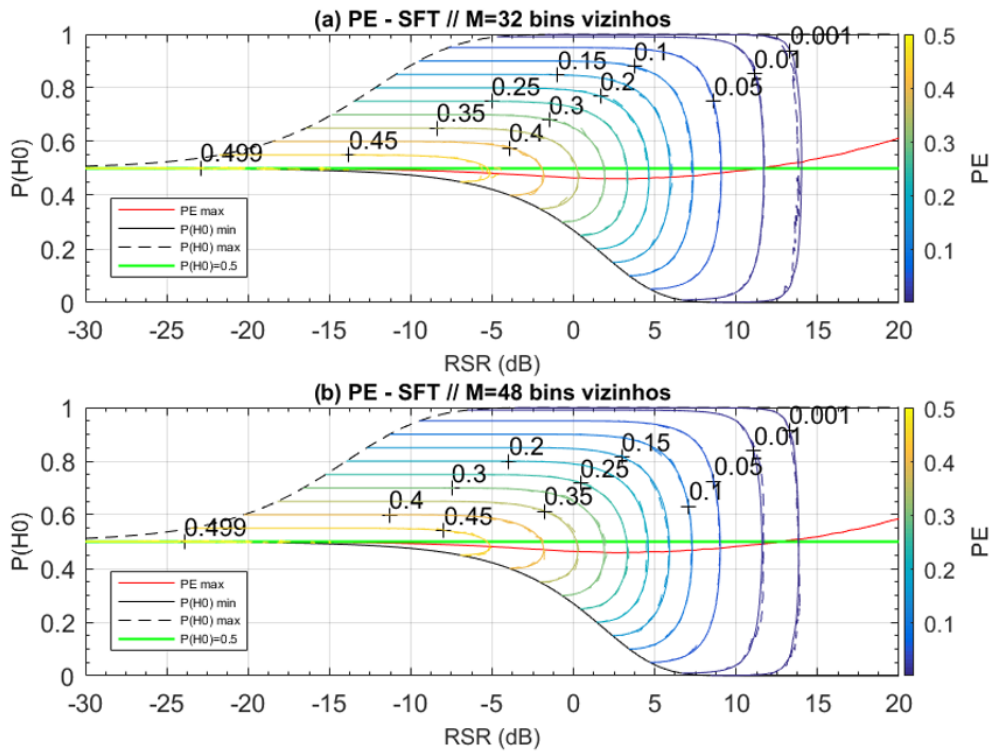


Figura 12 – Desempenho do detector bayesiano para SFT: (a)  $M = 32$ ; (b)  $M = 48$ .

Fonte: Dados da pesquisa.



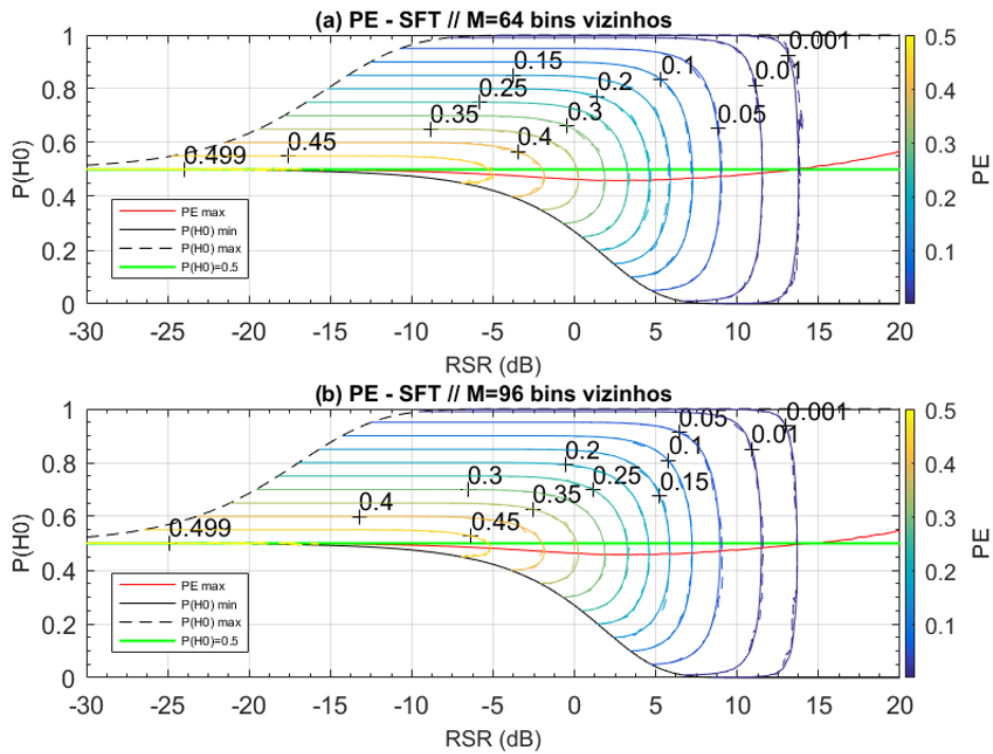


Figura 13 – Desempenho do detector bayesiano para SFT: (a)  $M = 64$ ; (b)  $M = 96$ .

Fonte: Dados da pesquisa.

É possível observar que as linhas de contorno de PE em todas as Figuras (10 a 13) não ocupam todo o plano formado por RSR e  $P(H0)$ . As curvas “ $P(H0)$  min” (curva em preto sólido) e “ $P(H0)$  max” (curva em preto tracejado) delimitam, respectivamente, os limites mínimo e máximo que  $P(H0)$  pode assumir para cada valor de RSR.

Verifica-se que as curvas “ $P(H0)$  min” e “ $P(H0)$  max” se interceptam em  $RSR \approx -30$  dB, restringindo o intervalo de escolha para  $P(H0)$  a um único valor ( $P(H0) = 0,5$ ). Nesse ponto de operação ( $RSR \approx -30$  dB,  $P(H0) = 0,5$ ), o detector apresenta o pior desempenho possível, tendo uma  $PE = 0,50$ , conforme assinalado nas Figuras 10 a 13. À medida que a RSR cresce, a região delimitada por “ $P(H0)$  min” e “ $P(H0)$  max” se expande, resultando no aumento da faixa de valores que podem ser atribuídos a  $P(H0)$ , até cobrir todo o intervalo  $0 < P(H0) < 1$ , como pode ser observado em todos os casos para  $RSR > 10$  dB.

Dependendo da escolha de  $P(H0)$ , a performance do detector pode apresentar variações significativas para um mesmo valor de RSR. Para  $M = 16$  (Figura 11 (b)), por exemplo, em  $RSR = 0$  dB, a performance do detector pode variar no intervalo  $0,01 \leq PE \leq 0,35$  em função do valor atribuído à probabilidade a priori (vide na Figura 11 [b] as curvas de contorno que passam por  $RSR = 0$  dB). Uma análise comparativa entre as Figuras 10 a 13 (sobretudo entre  $M = 4$  [Figura 10] e  $M = 12$  [Figura 11 (a)]), permite observar que a performance do detector também é afetada pelo número de bins escolhidos

na estimação do ruído. Nota-se que à medida que o valor de  $M$  aumenta, as curvas de contorno tendem a se deslocar para a esquerda e o espaçamento entre elas diminui. Além disso, o intervalo  $0 < P(H0) < 1$  será coberto pelas curvas “ $P(H0)$  min” e “ $P(H0)$  max” a partir de valores de RSR cada vez menores. Essas variações nas curvas de performance causadas por  $M$  resultam na redução da probabilidade de erro do detector em todos os pontos de operação. Ressalta-se, contudo, que para valores de  $M > 12$ , a melhoria no desempenho é pouco expressiva, assim como observado para o detector NP.

Haja vista que a probabilidade de erro depende tanto da RSR quanto de  $P(H0)$ , constata-se que há inúmeras estratégias que podem ser utilizadas a fim de se determinar os limiares de decisão para o teste bayesiano ( $\phi_{crit Bayes}$ ). As curvas de contorno mostram, entretanto, que, para um dado valor de  $P(H0)$ , a probabilidade de erro diminui à medida que a RSR aumenta. Por outro lado, quando se fixa um valor para RSR, nota-se que a PE diminui à medida que  $P(H0)$  se afasta de  $P(H0) = 0,5$ , seja em direção ao limite máximo ( $P(H0) \rightarrow 1$ ) ou mínimo ( $P(H0) \rightarrow 0$ ). Desta forma, a ocorrência das menores probabilidades de erro é percebida quando  $P(H0)$  é escolhido de forma a coincidir com as curvas “ $P(H0)$  max” e “ $P(H0)$  min”. A curva “PE max” (vermelho sólido das Figuras 10 a 13), por outro lado, indica os valores de  $P(H0)$  que resultam na maior probabilidade de erro associado a cada valor de RSR.

Assim, o desempenho do detector foi avaliado para as duas estratégias de escolha de  $P(H0)$  que resultam nas menores probabilidades de erro (“ $P(H0)$  max” e “ $P(H0)$  min”) e para aquela que resulta no pior desempenho possível (“PE max”). Além destas, foi adotada uma quarta estratégia na qual o valor da probabilidade a priori foi mantida constante em  $P(H0) = 0,5$  independentemente do valor da RSR (linha verde das Figuras 10 a 13). Essa última estratégia representa a situação na qual as duas hipóteses são equiprováveis. Os resultados são apresentados na Figura 14 e se referem ao levantamento realizado para  $M = 16$ .

Na Figura 14 (a) estão as curvas que descrevem os valores críticos ( $\phi_{crit Bayes}$ ) associados às diferentes estratégias adotadas na escolha de  $P(H0)$  e a estimativa de  $\phi(f_0)$  (linha vermelha tracejada) em função da RSR. A Figura 14 (b) apresenta o desempenho do detector associado às diferentes escolhas de  $P(H0)$ .

Na Figura 14 (a) é possível observar que os valores críticos que definem as regiões de decisão ( $\phi_{crit Bayes}$ ) variam em função da RSR, diferentemente do detector NP, que mantém o limiar constante para todo valor de RSR (vide Figura 9). A única exceção ocorre para “ $P(H0)$  min” (linha preta sólida na Figura 14 (a)), situação na qual o limiar se mantém em zero independentemente da RSR. As estratégias “ $P(H0) = 0,5$ ” e “PE max” possuem limiares de decisão muito próximos entre si, que se mantêm constantes ( $\phi_{crit Bayes:Max PE} \approx \phi_{crit Bayes: P(H0)=0,5} \approx 1$ ) até  $RSR \approx 5$  dB, apresentando comportamento crescente a partir desse valor.

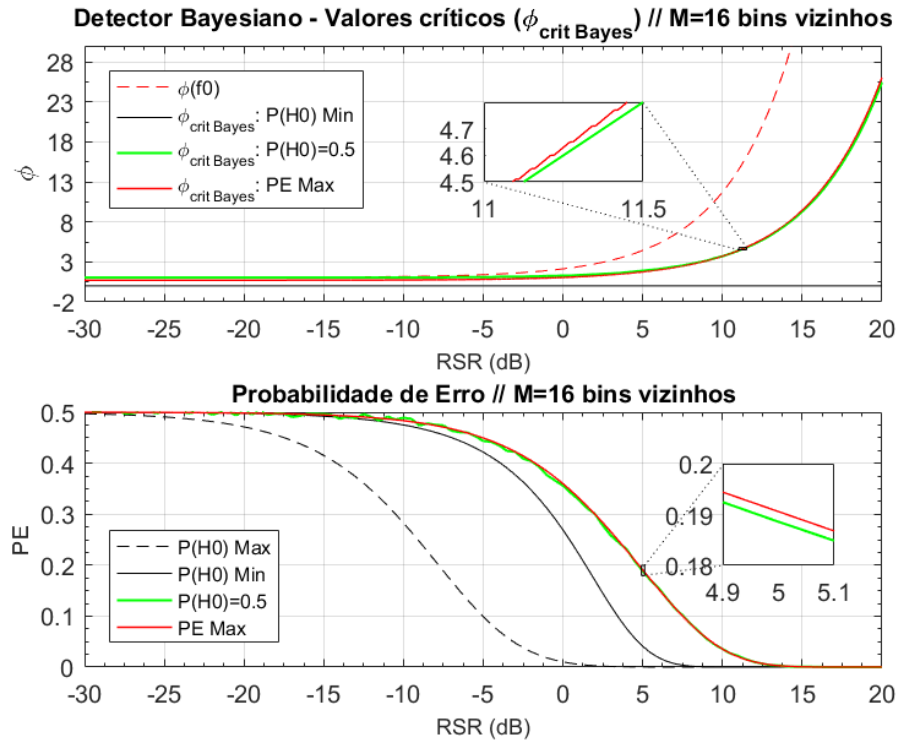


Figura 14 – Detector bayesiano para SFT ( $M=16$ ): (a) Relação entre  $\phi(f_0)$  (vermelho tracejado) e os limiares de decisão ( $\phi_{crit Bayes}$ ) para as quatro estratégias adotadas na escolha de  $P(H_0)$ : “ $P(H_0)$  max” (preto tracejado); “ $P(H_0)$  min” (preto sólido); “ $P(H_0) = 0,5$ ” (verde) e “PE max” (vermelho sólido); (b) Desempenho do detector (Prob. Erro - PE) para as quatro estratégias adotadas.

Fonte: Dados da pesquisa.

Nota-se que “ $P(H_0)$  max” é a estratégia que apresenta o melhor desempenho, atingindo  $PE=0$  em  $RSR \approx 0$  dB, como se pode verificar na Figura 14 (b) (linha tracejada preta). Porém, para essa estratégia, os valores críticos tendem ao infinito, independentemente da RSR. Por esse motivo, o traçado associado à “ $P(H_0)$  max” não consta na Figura 14 (a). Consequentemente,  $\phi(f_0)$  nunca irá ultrapassar o limiar  $\phi_{crit Bayes: P(H_0) max}$  resultando, portanto, na rejeição da hipótese alternativa em todos os casos.

Por outro lado, para as outras três estratégias, o valor de  $\phi(f_0)$  ultrapassa os respectivos limiares a partir de  $RSR = -30$  dB, o que leva à decisão pela hipótese alternativa ( $H_1$ ) mesmo para valores de RSR muito baixos. Contudo, a Figura 14 (b) mostra que, embora haja detecção, a probabilidade de erro se mantém próxima do seu valor máximo ( $PE \approx 0,5$ ) até aproximadamente  $RSR = -10$  dB, indicando que a decisão por  $H_1$  equivale a um palpite aleatório entre as duas hipóteses. Observa-se que para  $RSR > -10$  dB, a estratégia “ $P(H_0)$  min” foi a que apresentou melhor desempenho, atingindo  $PE=0$  para  $RSR > 7,5$  dB, enquanto as outras duas (“PE max” e “ $P(H_0) = 0,5$ ”), além de apresentarem performances muito próximas entre si (vide as regiões ampliadas na Figura 14), foram aquelas com pior desempenho, atingindo  $PE = 0$  somente para  $RSR > 12,5$  dB.

No Apêndice B estão as curvas que descrevem o comportamento geral dos limiares de decisão ( $\phi_{crit Bayes}$ ) em função da RSR e da escolha de  $P(H_0)$ , levando em consideração os demais valores de  $M$  analisados.

#### 4.1.2 Desempenho para MSC

Nesta seção são apresentados os resultados referentes à aplicação dos detectores NP e bayesiano ao teste MSC.

##### 4.1.2.1 Detector NP

A Figura 15 e a Figura 16 apresentam as curvas ROC do detector NP em relação à MSC para os diversos valores considerados para  $N$  (janelas).

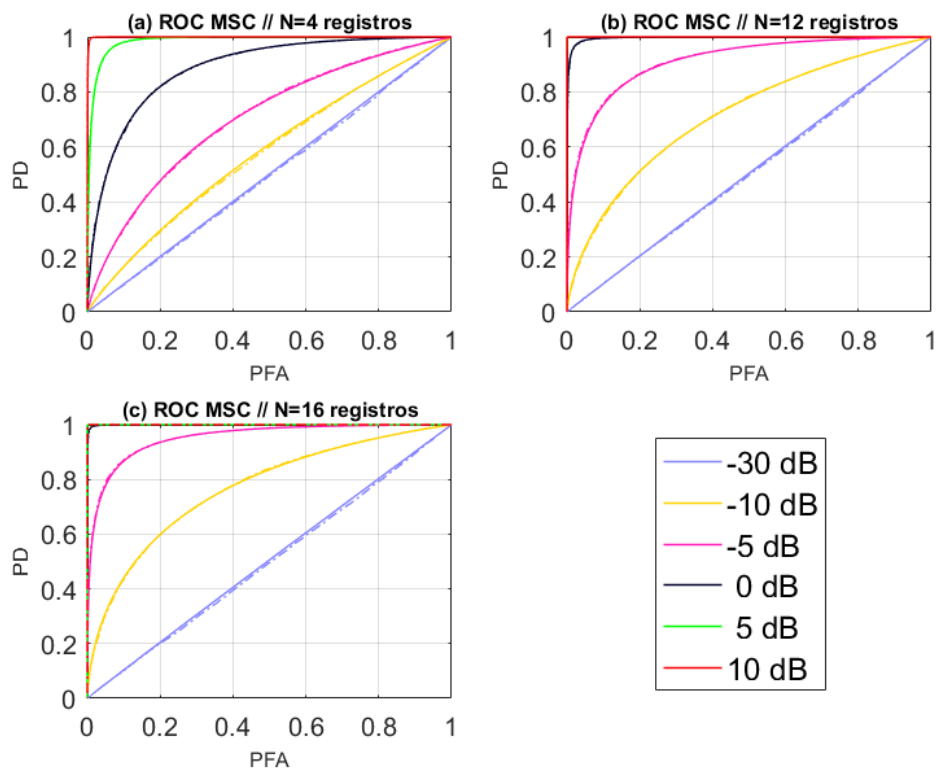


Figura 15 – Curvas ROC do detector NP aplicado à MSC para diversos valores de  $N$  analisados. Nas legendas estão indicados os valores de RSR (em dB) considerados. Os desempenhos teórico e de simulação são apresentados pelas linhas sólidas e tracejadas, respectivamente: (a)  $N=4$ ; (b)  $N=12$ ; (c)  $N=16$ .

Fonte: Dados da pesquisa.

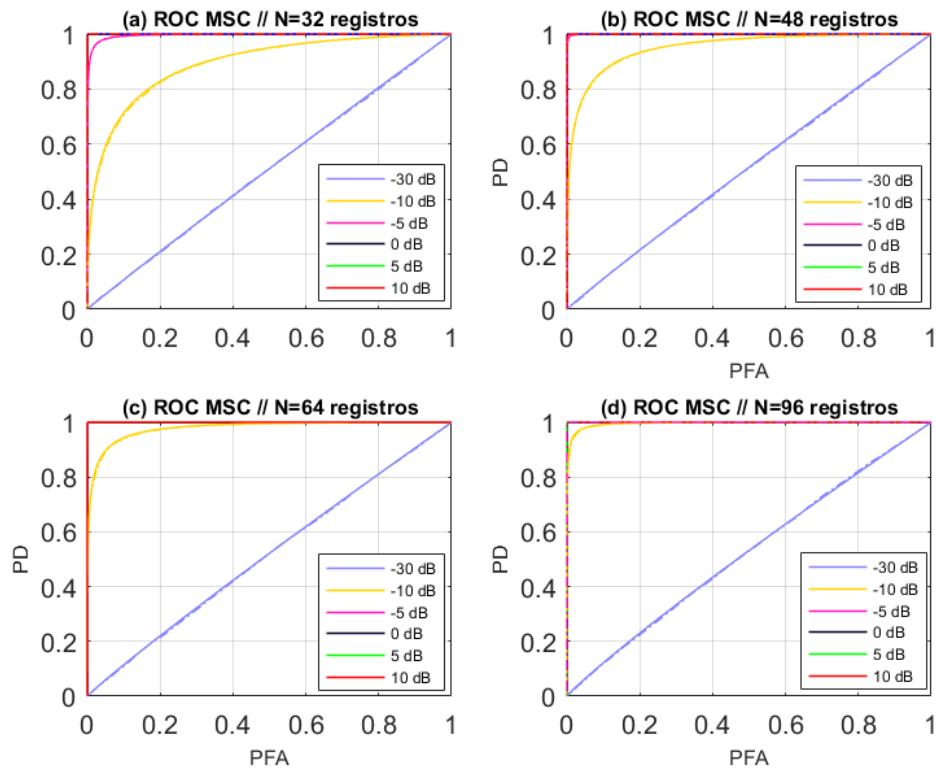


Figura 16 – Curvas ROC do detector NP aplicado à MSC para diversos valores de  $N$  analisados. Nas legendas estão indicados os valores de RSR (em dB) considerados. Os desempenhos teórico e de simulação são apresentados pelas linhas sólidas e tracejadas, respectivamente: (a)  $N=32$ ; (b)  $N=48$ ; (c)  $N=64$  e (d)  $N=96$ .

Fonte: Dados da pesquisa.

De maneira análoga ao que fora observado para SFT, o desempenho do detector NP melhora quanto mais alta for RSR, independentemente do número de registros ( $N$ ) utilizados na análise. Por outro lado, para a MSC, é possível observar uma melhora expressiva no desempenho à medida que  $N$  aumenta. Nota-se, por exemplo, que após o processamento de  $N = 96$  registros (Figura 16 (d)), apenas os sinais com RSR iguais a  $-10$  dB e  $-30$  dB não atingiram o ponto de operação ótimo.

A Figura 17 destaca o desempenho do detector NP para  $PFA=5\%$ , que corresponde ao nível de significância utilizado no processamento dos registros ASSR.

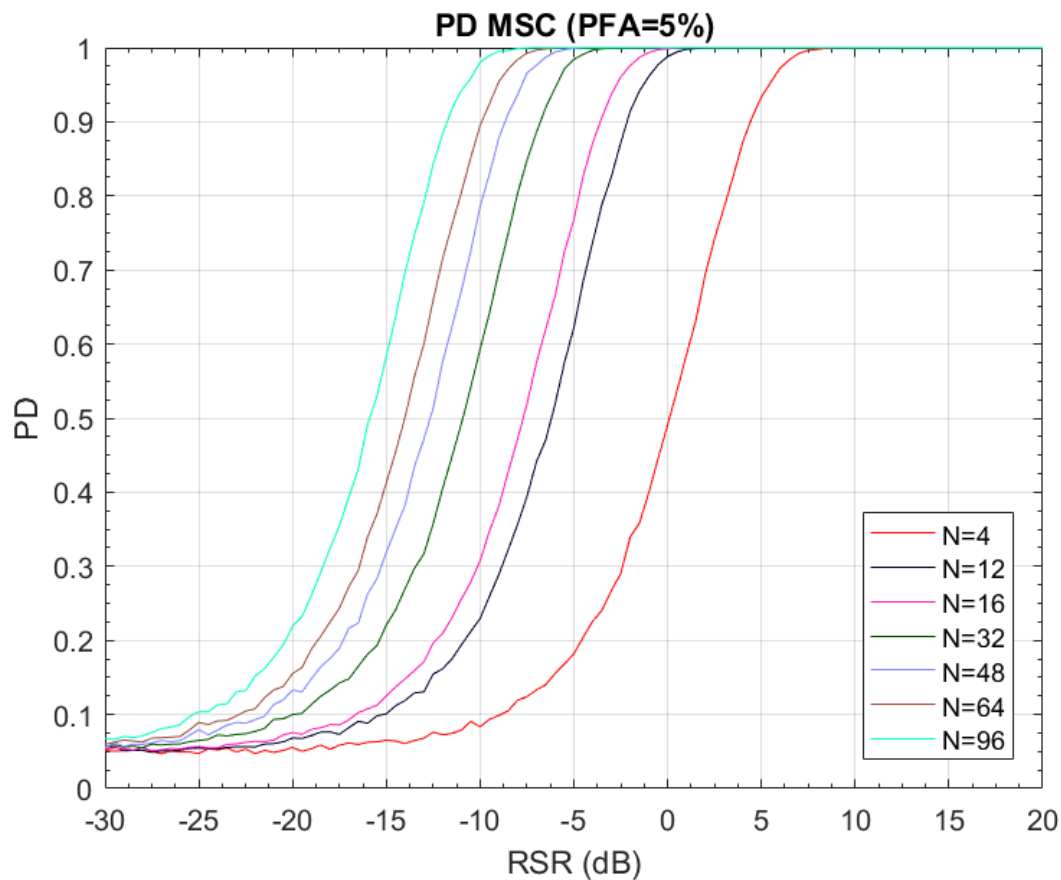


Figura 17 – Curvas PD do detector NP aplicado à MSC em função da RSR (em dB) para os diversos valores de  $N$  analisados (vide legenda), considerando  $PFA=0,05$ . As curvas representam os achados das simulações.

Fonte: Dados da pesquisa.

Os resultados da simulação apresentados pela Figura 17 permitem visualizar de forma mais clara a diferença no desempenho do detector em função de  $N$ .

#### 4.1.2.2 Detector Bayesiano

As Figuras 18 a 21 mostram o desempenho do detector bayesiano para a MSC (teórico: linhas de contorno sólidas; simulado: linhas de contorno tracejadas). A sequência de apresentação dos resultados segue uma ordem crescente em relação aos valores de  $N$  avaliados (Figura 18:  $N=4$ ; Figura 19: (a)  $N=12$ , (b)  $N=16$ ; Figura 20: (a)  $N=32$ , (b)  $N=48$ ; Figura 21: (a)  $N=64$ , (b)  $N=96$ ).

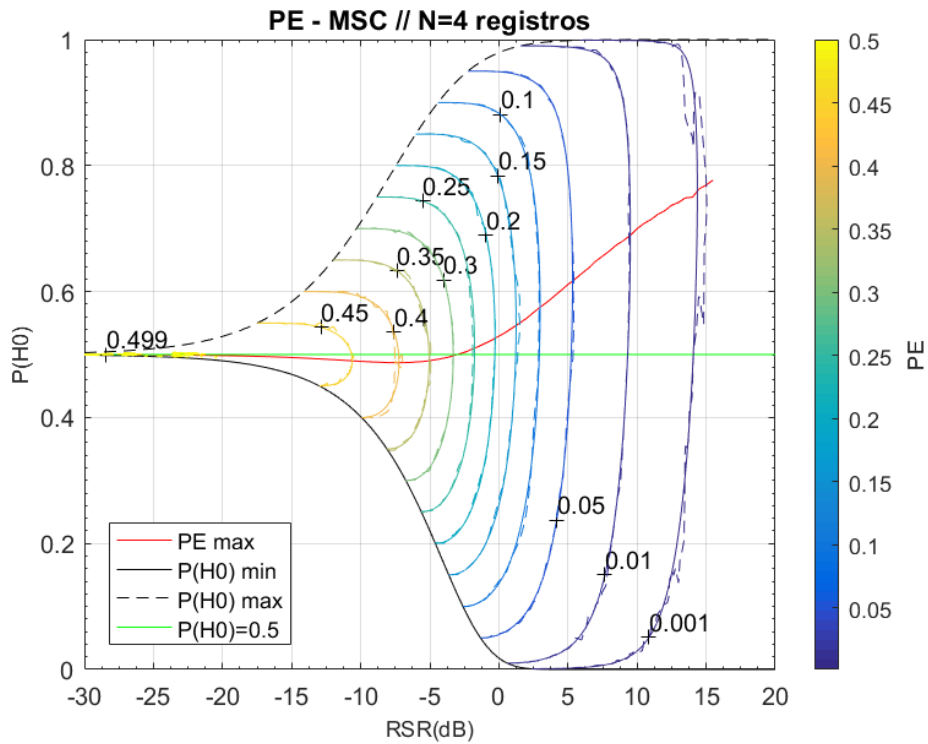


Figura 18 – Desempenho do detector bayesiano (PE) para MSC (teórico – curvas de contorno em linha sólida; simulado – curvas de contorno em linha tracejada) em função da RSR e  $P(H_0)$ , para  $N = 4$ . Os valores de PE estão indicados sobre cada linha de contorno (+) e pela barra de cores à direita. As curvas indicadas na legenda representam quatro estratégias distintas utilizadas na escolha de  $P(H_0)$ : “PE max” (vermelho sólido), “ $P(H_0)$  min” (preto sólido), “ $P(H_0)$  max” (preto tracejado) e “ $P(H_0) = 0,5$ ” (verde sólido).

Fonte: Dados da pesquisa.

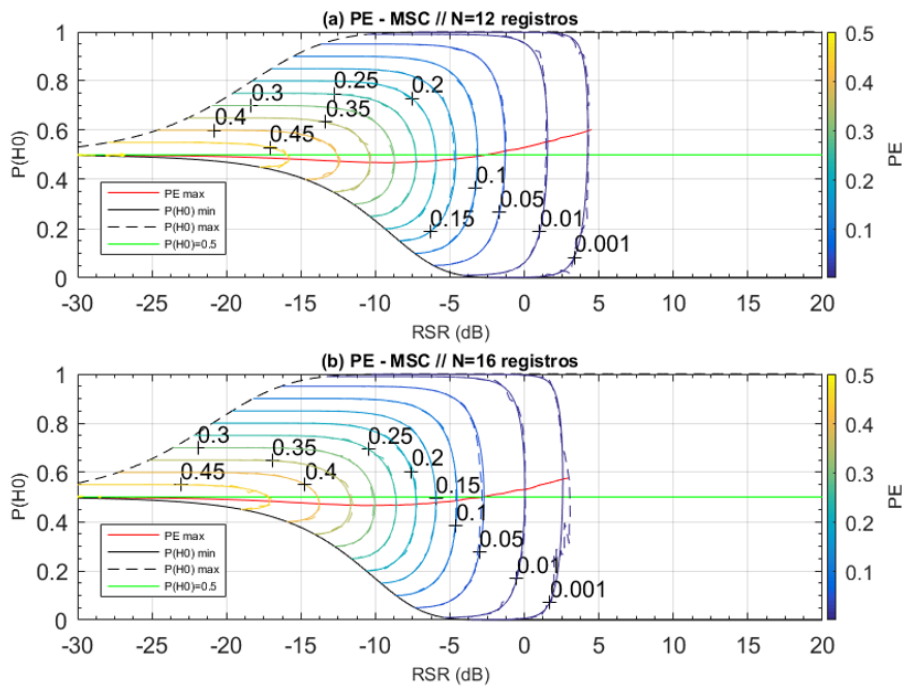


Figura 19 – Desempenho do detector bayesiano (PE) para MSC: (a)  $N=12$ ; (b)  $N=16$

Fonte: Dados da pesquisa.

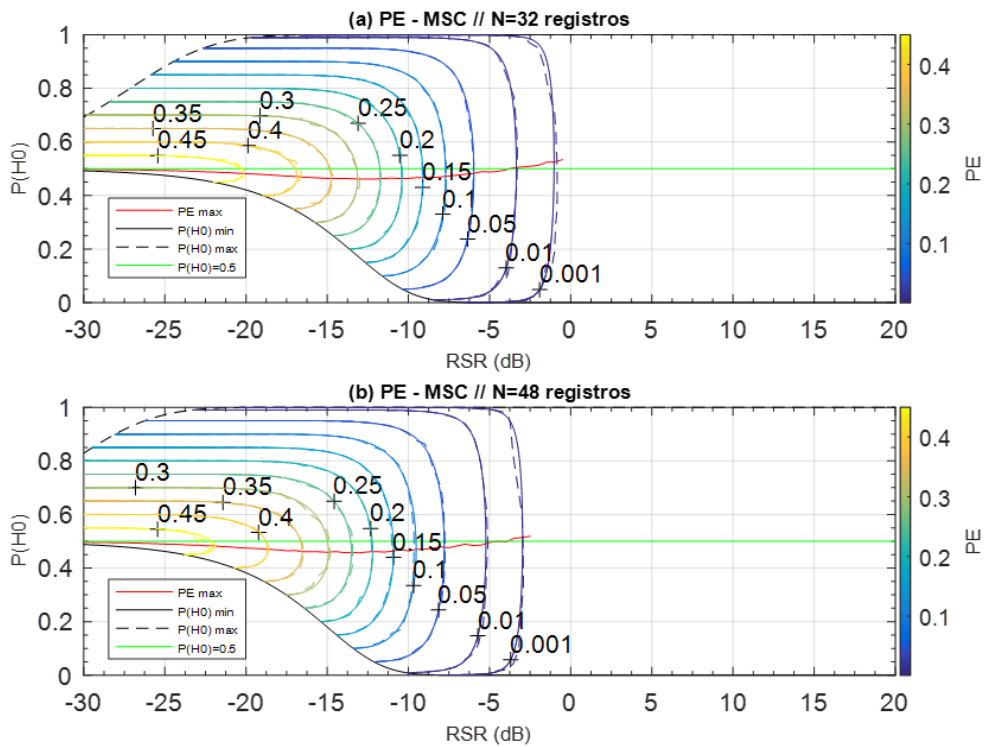


Figura 20 – Desempenho do detector bayesiano (PE) para MSC: (a)  $N=32$ ; (b)  $N=48$

Fonte: Dados da pesquisa.

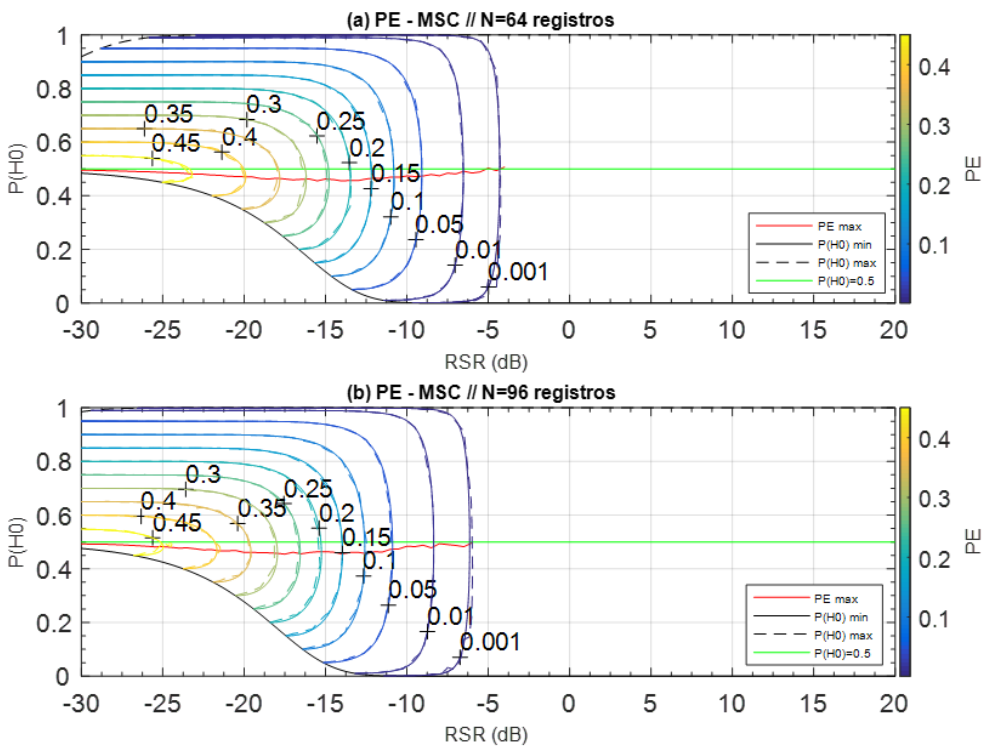


Figura 21 – Desempenho do detector bayesiano (PE) para MSC: (a)  $N=64$ ; (b)  $N=96$

Fonte: Dados da pesquisa.



De um modo geral, as Figuras 18 a 21 mostram que a probabilidade de erro para MSC apresenta um padrão de desempenho análogo àquele observado para SFT, ou seja, o valor das curvas de contorno diminuem à medida que a RSR aumenta e à medida que  $P(H_0)$  se afasta de  $P(H_0) = 0,5$ . Da mesma forma, as curvas “ $P(H_0)$  min” e “ $P(H_0)$  max” delimitam, respectivamente, os valores mínimos e máximos de  $P(H_0)$ .

Para a MSC, no entanto, fica mais evidente o deslocamento das curvas de contorno para a esquerda à medida que mais registros ( $N$ ) são utilizados no processamento. Além disso, é possível observar com mais clareza que a curva referente à probabilidade de erro máxima (“PE max”) se aproxima da curva “ $P(H_0) = 0,5$ ”, à medida que  $N$  aumenta.

Seguindo o mesmo procedimento utilizado para a SFT, foi realizado o levantamento das curvas referentes aos limiares críticos ( $k^2_{crit Bayes}$ ) em relação às quatro estratégias adotadas na escolha de  $P(H_0)$  (“ $P(H_0)$  min”, “ $P(H_0)$  max”, “PE max” e “ $P(H_0) = 0,5$ ”). Os resultados são apresentados a seguir (Figura 22) para  $N = 16$ .

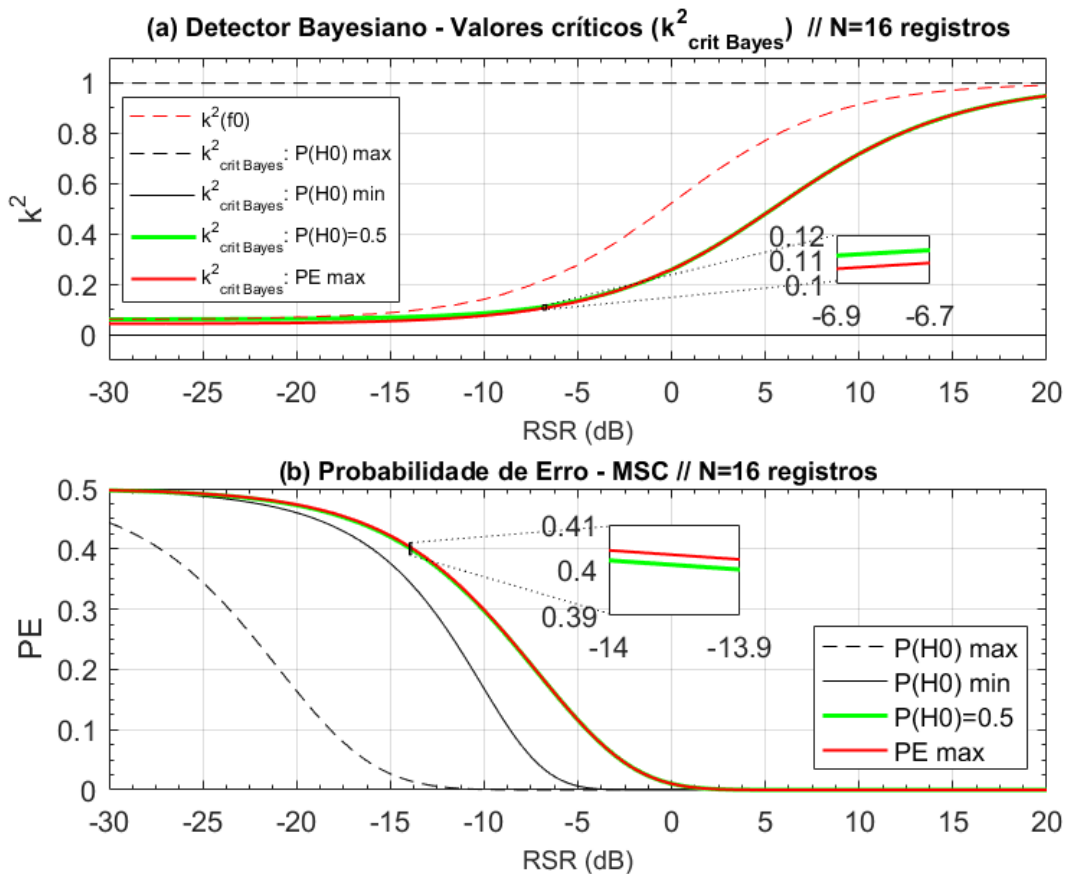


Figura 22 – Detector bayesiano para MSC ( $N=16$ ): (a) Relação entre  $k^2(f_0)$  (vermelho tracejado) e os limiares de decisão ( $k^2_{crit Bayes}$ ) para as quatro estratégias adotadas na escolha de  $P(H_0)$ : “ $P(H_0)$  max” (preto tracejado); “ $P(H_0)$  min” (preto sólido); “ $P(H_0) = 0,5$ ” (verde) e “PE max” (vermelho sólido); (b) Desempenho do detector (Prob. Erro - PE) para as quatro estratégias adotadas.

Fonte: Dados da pesquisa.

Os resultados apresentados pela Figura 22 (a) mostram que os limiares  $k^2_{crit Bayes}$  para as estratégias “ $P(H0)$  min” e “ $P(H0)$  max” ocupam posições extremas, assumindo valores constantes em, respectivamente,  $k^2 = 0$  e  $k^2 = 1$ . Desta forma, para a estratégia “ $P(H0)$  min” haverá detecção para todos os casos, tendo em vista que  $k^2(f_0)$  será nulo apenas quando  $SNR_{dB} \rightarrow -\infty$ . Por outro lado, para “ $P(H0)$  max”, não haverá detecção quaisquer que sejam os valores de RSR, tendo em vista que  $k^2(f_0)$  cresce assintoticamente em direção a  $k^2 = 1$  (curva vermelha tracejada na Figura 22 (a)). Em relação à probabilidade de erro (Figura 22 (b)), é possível observar que, de forma semelhante ao SFT, a estratégia “ $P(H0)$  max” apresenta o melhor desempenho possível para o detector, seguido por “ $P(H0)$  min”. As estratégias “PE max” e “ $P(H0) = 0,5$ ”, assim como em SFT, têm comportamentos muito próximos entre si (vide as regiões ampliadas na Figura 22). Conforme apresentado na Figura 22 (a), nota-se que o valor esperado da MSC ( $k^2(f_0)$ ) é maior ou igual aos limiares destas duas estratégias para quaisquer valores de RSR (curvas verde e vermelha sólidas da Figura 22 (a)), o que leva à decisão pela hipótese  $H1$  em todos os casos. Em relação ao desempenho, conforme esperado, estas duas estratégias apresentam os piores resultados possíveis para o detector. No Apêndice C são apresentadas as figuras que relacionam os valores críticos  $k^2_{crit Bayes}$  em função da RSR e do valor de  $P(H0)$ , para todos os valores de  $N$  analisados.

### 4.1.3 Paralelo entre os detectores NP e Bayesiano

Nessa seção são apresentadas duas análises que visam a relacionar os resultados encontrados para os detectores NP e bayesiano (tanto para SFT quanto para MSC). A primeira busca evidenciar a relação existente entre a curva ROC (usada para o detector NP) e as curvas de contorno referentes a PE (utilizadas para o detector bayesiano). Já a segunda visa a estabelecer um paralelo entre as curvas de performance PD e PE.

#### 4.1.3.1 Curva ROC vs. Mapas de contorno de PE

Conforme apresentado na seção 2.3.3, a curva ROC pode ser utilizada para descrever tanto a PD (detector NP) quanto a PE (detector bayesiano). Desta forma, a Figura 23 exhibe um exemplo de como os pontos de operação da curva ROC apresentam uma correspondência com as curvas de contorno do detector bayesiano. Neste caso, os resultados apresentados se referem à performance de SFT considerando  $M=16$ .

Para exemplificar diferentes pontos de operação, foram assinalados na Figura 23 (a) seis círculos em vermelho, que estão indicados por números (1 a 6). Próximo a cada círculo, constam os valores de  $P(H0)$  e PE associados ao respectivo ponto de operação ( $PFA, PD$ ). Os valores de  $P(H0)$  foram encontrados avaliando-se a equação 46 e a equação

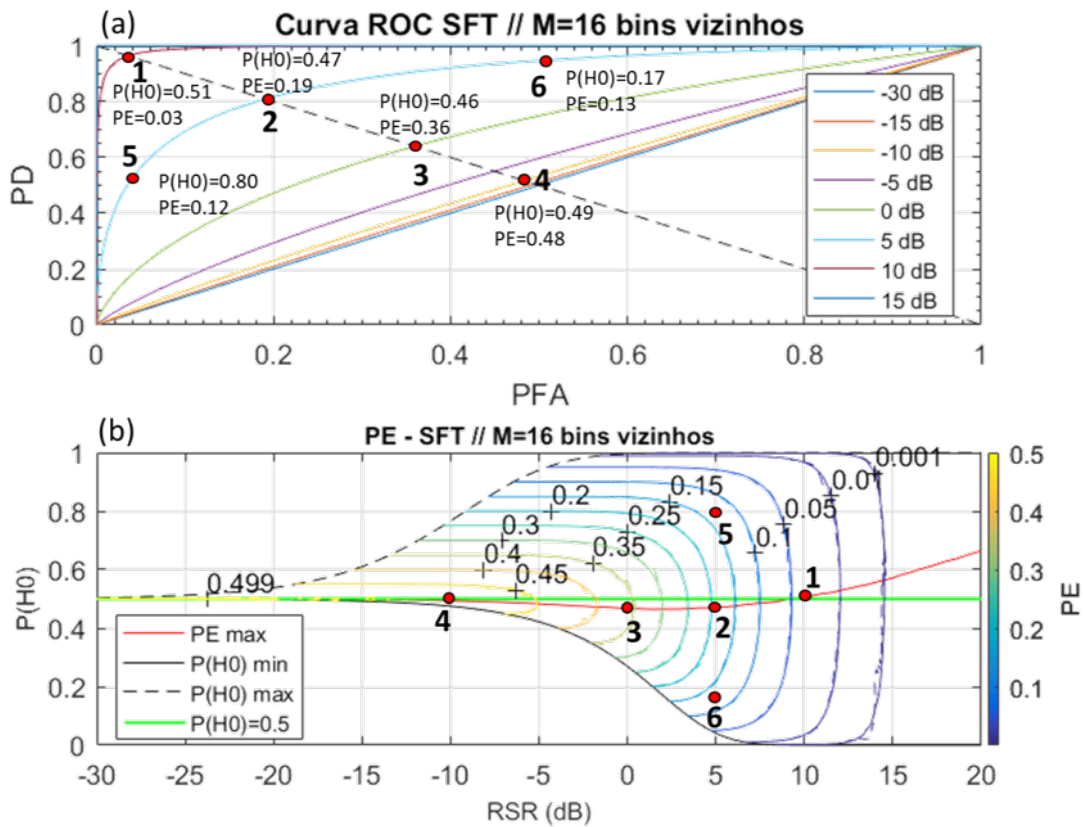


Figura 23 – Relação entre a curva ROC e a performance do detector bayesiano para SFT ( $M=16$ ). Os seis círculos em vermelho enumerados em ambos os gráficos representam exemplos de pontos de operação: (a) Curva ROC (a reta tracejada representa a função  $PD = 1 - PFA$ ); (b) Curvas de contorno referentes a PE.

Fonte: Dados da pesquisa.

50. Para a determinação de PE, foi utilizada a equação 41. Assim, os pontos de operação associados a cada círculo são:

- Círculo 1:  $RSR = 10$  dB;  $P(H_0) = 0,51$  e  $PE = 0,03$ ;
- Círculo 2:  $RSR = 5$  dB;  $P(H_0) = 0,47$  e  $PE = 0,19$ ;
- Círculo 3:  $RSR = 0$  dB;  $P(H_0) = 0,46$  e  $PE = 0,36$ ;
- Círculo 4:  $RSR = -10$  dB;  $P(H_0) = 0,49$  e  $PE = 0,48$ ;
- Círculo 5:  $RSR = 5$  dB;  $P(H_0) = 0,80$  e  $PE = 0,12$ ;
- Círculo 6:  $RSR = 5$  dB;  $P(H_0) = 0,17$  e  $PE = 0,13$ ;

De posse dos valores de  $P(H_0)$  e sabendo o valor da RSR, foi possível identificar nas curvas de contorno apresentadas na Figura 23 (b) a localização dos seis pontos de interesse. Como pode ser observado, os círculos 1, 2, 3 e 4, que estão sobre a reta tracejada no gráfico da Figura 23 (a), aparecem sobre a curva “PE max” (Figura 23 (b)). Isso comprova, conforme mostrado na seção 2.3.3.1, que a reta  $PD = 1 - PFA$  abriga os

pontos de operação com máxima probabilidade de erro. A análise da disposição dos círculos 2, 5 e 6 na curva ROC (Figura 23 (a)) também mostram que, para uma dada RSR, a PE diminui à medida em que o ponto de operação se afasta da reta  $PD = 1 - PFA$ , seja em direção ao ponto  $[PD=0;PFA=0]$  ou para  $[PD=1;PFA=1]$ . Ressalta-se, entretanto, que a redução no valor de PE causada pela adoção desse procedimento dependerá da RSR. No caso extremo em que  $SNR_{dB} \rightarrow -\infty$ , a probabilidade de erro será igual a 50% ( $PE = 0,5$ ) para todos os pontos sobre a respectiva curva ROC. É possível observar também que os pontos 5 e 6 apresentam performances muito próximas entre si ( $PE = 0,12$  e  $PE = 0,13$ , respectivamente). Contudo, apesar da similaridade nas performances, deve-se destacar que esses dois pontos representam situações distintas. A probabilidade a priori  $P(H_0) = 0,80$  (associada ao ponto 5) provoca um aumento da região de decisão para a hipótese  $H_0$ , causando uma redução do erro tipo I (porém, levando ao aumento do erro tipo II). Já no ponto 6, observa-se a situação inversa, ou seja, a probabilidade a priori  $P(H_0) = 0,17$  causa uma redução do erro tipo II em detrimento do aumento do erro tipo I. Desta forma, a escolha da probabilidade a priori  $P(H_0)$  deve levar em consideração a relevância desses dois tipos de erro em relação ao estudo que está sendo conduzido.

#### 4.1.3.2 Relação entre PD e PE

A Figura 24 traz uma sobreposição das curvas de desempenho obtidas para os detectores NP e bayesiano, tanto para SFT (Figura 24 (a)) quanto para MSC (Figura 24 (b)). Para comparar as duas abordagens, as curvas de performance do detector bayesiano são apresentadas na forma de probabilidade de acerto (PA) (equação 42). Esse procedimento foi utilizado para que as curvas de desempenho do detector bayesiano apresentassem comportamento crescente, possibilitando uma comparação em relação à PD da abordagem NP. Nesta análise, entretanto, foram consideradas apenas as estratégias “ $P(H_0)$  min” e “ $P(H_0) = 0,5$ ”. A estratégia “ $P(H_0)$  max” foi excluída por resultar em um limiar de decisão muito elevado, inviabilizando a detecção de respostas. A estratégia “PE max” também não foi considerada, por apresentar um desempenho muito próximo à “ $P(H_0) = 0,5$ ”.

Embora sejam medidas de desempenho que possuem diferentes interpretações, é desejado que tanto PD quanto PA apresentem uma taxa de crescimento elevada e atinjam o nível máximo (100%) para o menor valor de RSR possível. Com base nessa premissa, é possível observar que o detector bayesiano, mesmo em sua pior performance (linhas vermelhas da Figura 24), atinge elevados patamares antes do detector NP (linhas azuis da Figura 24), tanto para SFT quanto para MSC. Pode-se observar que PD intercepta “ $PA[P(H_0) = 0,5]$ ”, quando ambas as curvas estão no patamar de 0,95, que já é considerada uma performance de nível elevado.

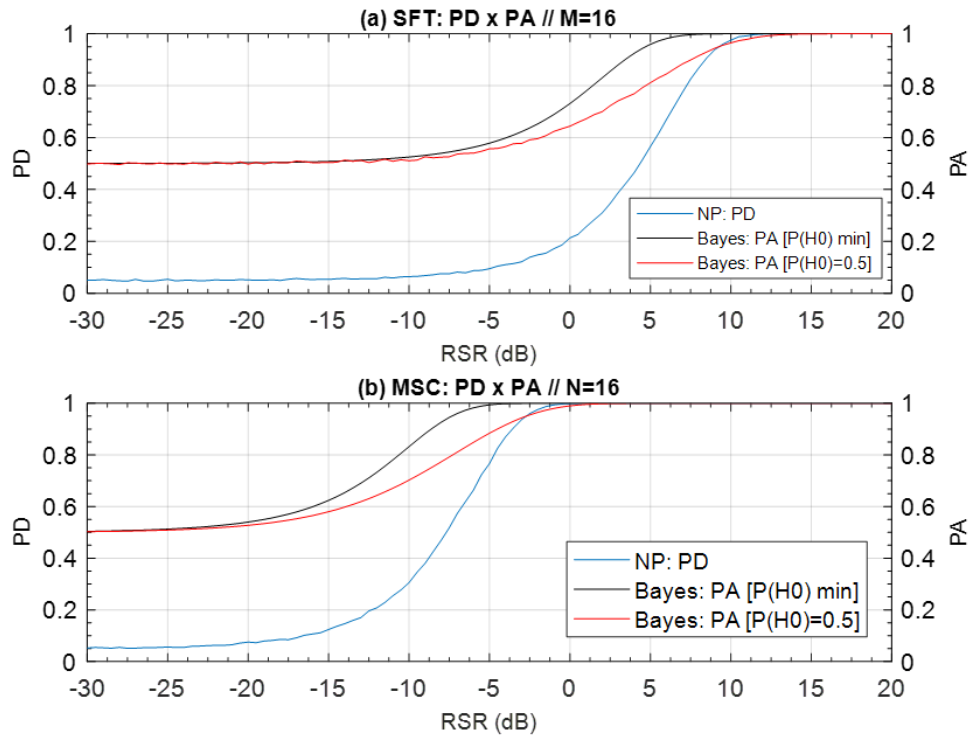


Figura 24 – Sobreposição das curvas de desempenho do detectores NP e bayesiano: Em azul, a curva PD, referente ao detector NP; Em preto e vermelho, as curvas PA do detector bayesiano, para as estratégias “ $P(H_0)$  min” e “ $P(H_0) = 0,5$ ”, respectivamente. (a) Performances para SFT [ $M=16$ ]; (a) Performances para MSC [ $N=16$ ].

Fonte: Dados da pesquisa.

#### 4.1.4 Relação entre MSC e SFT

Os resultados referentes à MSC (para ambos os detectores) mostram melhoras expressivas de desempenho à medida que o valor de  $N$  (janelas) aumenta, ao passo que para SFT a melhora no desempenho é pouco relevante a partir de  $M = 12$  (bins). Entretanto, é preciso ressaltar que, embora as avaliações de SFT e MSC tenham envolvido os mesmos valores para  $M$  e  $N$ , estes parâmetros representam grandezas distintas. Conforme apresentado na fundamentação teórica, em SFT, o valor de  $M$  representa o número de componentes espectrais utilizadas na estimação da potência do ruído, a partir da análise de um registro apenas. Já na MSC, o valor de  $N$  indica o número de registros utilizados no cálculo da coerência.

Desta forma, não se deve comparar o desempenho destas duas técnicas ORD relacionando diretamente os cenários nos quais  $M = N$ . Tal procedimento levará à conclusão (equivocada) de que o desempenho de MSC é muito superior ao SFT. Para que os dois métodos possam ser comparados, é preciso levar em consideração o número de registros  $N$  (utilizados pela MSC) no momento de se calcular o SFT.

Considere, por exemplo, um cenário no qual a MSC é calculada a partir da

coleta de  $N = 32$  registros, em que cada registro apresenta uma  $RSR = -10$  dB. O desempenho de MSC para esse caso será dado pela curva amarela apresentada no gráfico da Figura 16 (a). A análise deste mesmo cenário em relação ao SFT deve levar em consideração a promediação temporal dos trinta e dois registros coletados. Procedendo desta forma, haverá uma melhoria da relação sinal/ruído, resultando em um novo registro com  $RSR = -10 + 10\log_{10}(N)$  (ROMÃO; TIERRA-CRIOLLO, 2020). Logo, este novo valor será  $RSR = -10 + 10\log_{10}(32) = 5,05$  dB.

Desta forma, para esse cenário hipotético, a comparação entre as duas técnicas ORD deve considerar o desempenho de MSC para  $N = 32$  e  $RSR = -10$  dB em relação ao SFT para  $RSR \approx 5$  dB e em função de todos os valores de  $M$  (bins) considerados. A Figura 25 apresenta a sobreposição das respectivas curvas de desempenho encontradas para este cenário.

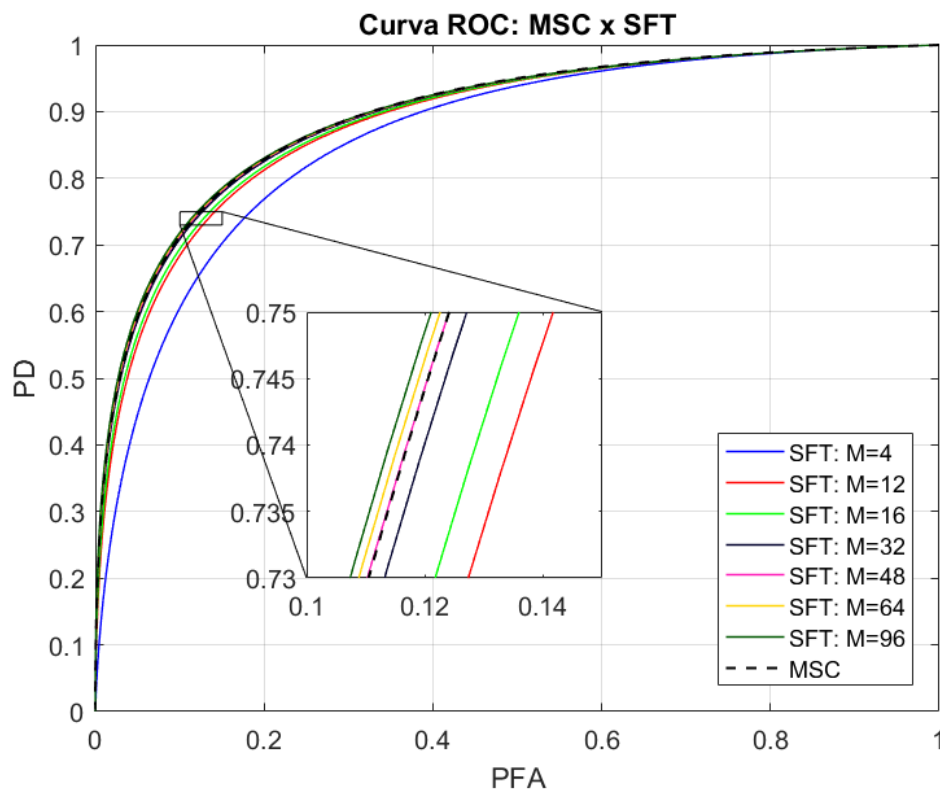


Figura 25 – Comparação de desempenho das curvas ROC de MSC ( $N = 32$ ;  $RSR = -10$  dB; preto tracejado) em relação ao SFT ( $M=[4,12,16,32,48,64,96]$ ;  $RSR \approx 5$  dB).

Fonte: Dados da pesquisa.

A linha tracejada preta da Figura 25 representa o desempenho de MSC ( $N=32$  e  $RSR = -10$  dB), enquanto as demais representam o desempenho de SFT ( $RSR \approx 5$  dB) relativo aos valores de  $M$  (bins) considerados. Com base nesta figura é possível constatar que a partir de  $M = 12$ , os desempenhos das duas técnicas ORD são muito próximos entre si (vide a área ampliada na Figura 25).

## 4.2 ESTIMADORES

Nesta seção são apresentados os resultados referentes à análise dos estimadores para a RSR. Inicialmente, serão apresentados os achados para a aplicação ao teste SFT, na qual foram investigadas as performances para a estimação de um sinal ( $RSR > 0$ ) e de um ruído ( $RSR = 0$ ). Em seguida são apresentados os resultados encontrados para a MSC, nos quais também foram analisados esses dois cenários.

### 4.2.1 Aplicação para SFT

A Figura 26 traz os resultados do cenário hipotético para estimação de um sinal com  $RSR_{dB} = 0$  dB ( $RSR = 1$ ). Nesta figura são apresentados também os resultados da estimação a partir da equação do valor esperado da distribuição F não central (vide “Analít (SFT)” na legenda) e o estimador de máxima verossimilhança (MLE). Nas legendas estão indicadas também as distribuições a priori utilizadas no estimador bayesiano.




Figura 26 – Performances dos estimadores (MAP) aplicados ao SFT quando  $RSR=1$  (sinal). As curvas  $N(1; 0,001)$ ;  $N(1,5; 0,001)$ ;  $U(0; 100)$ ;  $N(1; 1)$  e  $N(1,5; 1)$  se referem às cinco distribuições escolhidas para a priori  $P(RSR)$ . A curva “Analít. (SFT)” se refere ao estimador baseado na equação do valor esperado da distribuição F não central. “MLE” representa o estimador de máxima verossimilhança e a linha preta tracejada horizontal indica o valor real da RSR considerada na simulação. A região ampliada dá destaque às performances nas primeiras iterações.

Fonte: Dados da pesquisa.

Uma análise geral da Figura 26 mostra que em todos os casos as estimativas para RSR tendem assintoticamente para o valor real. No caso da estimação bayesiana, entretanto, a convergência para  $RSR = 1$  está diretamente ligada à escolha da probabilidade a priori  $P(RSR)$ . É possível observar que a pior convergência se deu para a priori  $N(\mu = 1, 5; \sigma^2 = 0.001)$ , cuja estimativa permaneceu distante do valor real mesmo após o processamento de 300 registros. Já o segundo pior desempenho ocorreu para  $N(\mu = 1, 5; \sigma^2 = 1)$ . Neste caso, entretanto, verifica-se que houve uma melhora expressiva na convergência do estimador causada pelo aumento na variância da distribuição a priori. No outro extremo, observa-se que o melhor desempenho ocorreu para a probabilidade a priori  $N(\mu = RSR = 1; \sigma^2 = 0.001)$ , na qual o estimador convergiu para o valor real a partir das primeiras iterações (vide a área ampliada na Figura 26). O segundo melhor desempenho, por sua vez, se deu para  $N(\mu = RSR = 1; \sigma^2 = 1)$ . Fica evidente nestes dois casos (em que a média é igual ao valor real da RSR) que o aumento da variância prejudica a convergência do estimador, ao contrário daquilo que fora observado para os dois piores desempenhos. Por fim, apresentando um desempenho intermediário (dentre todas as distribuições a priori analisadas), está a distribuição uniforme.

Quando o estimador MLE é levado em consideração, é possível constatar que o seu desempenho é aproximadamente igual àquele obtido para a probabilidade a priori uniforme a partir das primeiras iterações.

O estimador analítico (analít (SFT)) teve um desempenho melhor em relação ao outro método não bayesiano investigado (MLE). É possível verificar ainda que este estimador converge com o estimador bayesiano  $N(1;1)$  antes de se atingir a 50<sup>a</sup> iteração (vide região ampliada na figura).

A seguir são apresentados os resultados para a segunda análise conduzida em relação aos estimadores a partir de SFT, ou seja, aquela na qual foi considerada a estimativa de um ruído ( $RSR = 0$ ). A Figura 27 apresenta os resultados encontrados para o estimador MAP para as cinco distribuições a priori consideradas. Nesta figura foram incluídos também os estimadores MLE e aquele baseado na equação 7 (“Analít. (SFT)”).



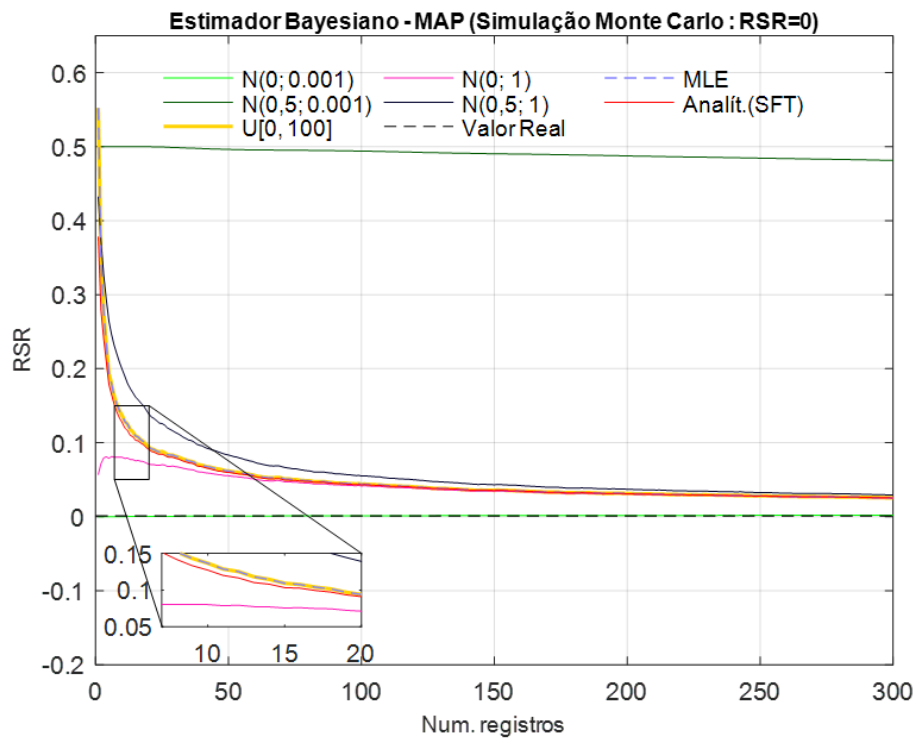


Figura 27 – Performances dos estimadores (MAP) aplicados ao SFT quando  $RSR=0$  (ruído). As curvas  $N(0; 0,001)$ ;  $N(0,5; 0,001)$ ;  $U(0; 100)$ ;  $N(0; 1)$  e  $N(0,5; 1)$  se referem às cinco distribuições escolhidas para a probabilidade a priori  $P(RSR)$ . A curva “Analít. (SFT)” se refere ao estimador baseado na equação do valor esperado da distribuição F não central. “MLE” representa o estimador de máxima verossimilhança e a linha preta tracejada horizontal indica o valor real da RSR considerada na simulação. A região ampliada dá destaque às performances nas primeiras iterações.

Fonte: Dados da pesquisa.

A partir da Figura 27 é possível ver que para o ruído também há a convergência assintótica de todos os estimadores analisados em direção  $RSR = 0$ . Neste cenário, entretanto, percebe-se que a convergência de todos os estimadores bayesianos ocorre de forma mais lenta (a exceção da distribuição a priori  $N(RSR = 0; \sigma^2 = 0.001)$ , se comparado ao cenário no qual foi estimado um sinal ( $RSR > 0$ ). Nota-se que as estimativas ainda são consideravelmente distantes do valor real, mesmo após a análise de 300 registros.

Dentre os estimadores bayesianos, assim como observado em  $RSR > 0$ , após 300 registros analisados,  $N(RSR = 0; \sigma^2 = 0.001)$  e  $N(RSR = 0, 5; \sigma^2 = 0.001)$  apresentaram o melhor e o pior desempenhos, respectivamente.

Os estimadores MLE, “Analít. (SFT)” e o bayesiano para a distribuição a priori uniforme apresentaram performances aproximadamente iguais a partir das primeiras iterações. Já os estimadores bayesianos para as distribuições com maior variância ( $\sigma^2 = 1$ ) ocuparam posições opostas em relação àquelas três anteriores com desempenhos semelhantes. Neste caso, a probabilidade a priori  $N(RSR = 0; \sigma^2 = 1)$  apresentou um desempenho superior, enquanto  $N(RSR = 0, 5; \sigma^2 = 1)$  apresentou o segundo pior desempenho.

### 4.2.2 Aplicação para MSC

A seguir são apresentados os resultados para a estimação da RSR a partir da MSC, considerando os dois cenários analisados:  $RSR = 1$  (Figura 28) e  $RSR = 0$  (Figura 29). As cores referentes a cada estimador seguem o mesmo padrão adotado para os resultados de SFT. Ressalta-se que, no caso da MSC, o estimador analítico foi aquele apresentado na equação 15 (vide “Analít. (MSC)” na legenda da Figura 28).




Figura 28 – Performances dos estimadores (MAP) aplicados à MSC quando  $RSR=1$  (sinal). As curvas  $N(1; 0,001)$ ;  $N(1,5; 0,001)$ ;  $U(0; 100)$ ;  $N(1; 1)$  e  $N(1,5; 1)$  se referem às cinco distribuições escolhidas a priori ( $P(RSR)$ ). A curva “Analít. (MSC)” se refere ao estimador baseado na equação 15. “MLE” representa o estimador de máxima verossimilhança e a linha preta tracejada horizontal indica o valor real da RSR considerada na simulação. A região ampliada dá destaque às performances nas primeiras iterações.

Fonte: Dados da pesquisa.

É possível observar que  $N(RSR = 1; \sigma^2 = 0,001)$  e  $N(RSR = 1,5; \sigma^2 = 0,001)$  apresentaram, respectivamente, o melhor e o pior desempenhos, assim como ocorreu para SFT. Contudo, é possível verificar que para a MSC os demais estimadores bayesianos convergem entre si e também em relação a MLE com o passar das primeiras iterações. Verifica-se também que o estimador analítico foi o que apresentou o segundo pior desempenho.

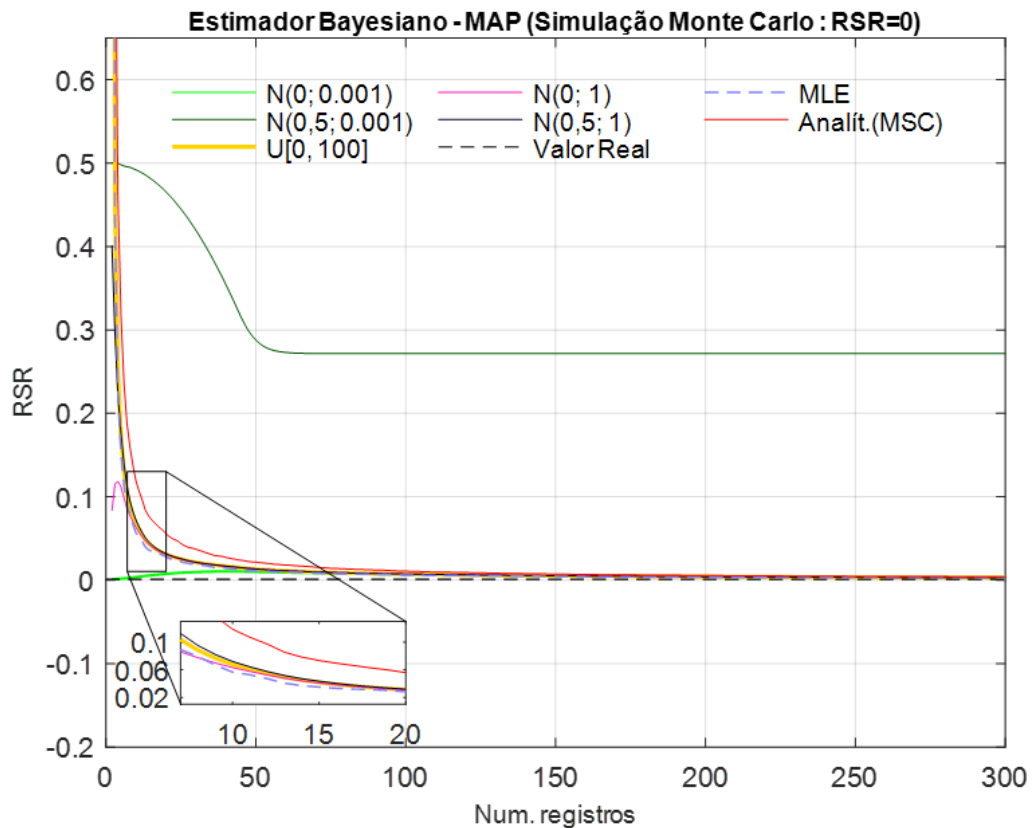


Figura 29 – Performances dos estimadores (MAP) aplicados à MSC quando  $RSR=0$  (ruído). As curvas  $N(0; 0,001)$ ;  $N(0,5; 0,001)$ ;  $U(0; 100)$ ;  $N(0; 1)$  e  $N(0,5; 1)$  se referem às cinco distribuições a priori escolhidas ( $P(RSR)$ ). A curva “Analít. (MSC)” se refere ao estimador baseado na equação 15. “MLE” representa o estimador de máxima verossimilhança e a linha preta tracejada horizontal indica o valor real da RSR considerada na simulação. A região ampliada dá destaque às performances nas primeiras iterações.

Fonte: Dados da pesquisa.

A Figura 29 mostra que as performances dos estimadores para o cenário  $RSR = 0$  seguiu o mesmo padrão apresentado para  $RSR = 1$ , ou seja,  $N(RSR = 0; \sigma^2 = 0,001)$  apresentou a melhor performance, ao passo que  $N(RSR = 0,5; \sigma^2 = 0,001)$  figurou como a de pior desempenho. Novamente,  $N(RSR = 0; \sigma^2 = 1)$ ,  $U(0,100)$ ,  $N(RSR = 0,5; \sigma^2 = 1)$  e MLE apresentaram performances semelhantes, enquanto “Analít. (MSC)” teve o segundo pior desempenho.

### 4.2.3 Definição dos estimadores para aplicação nos registros ASSR

Conforme exposto anteriormente (seção 3.2.1), as distribuições a priori escolhidas para a simulação visaram explorar o comportamento do estimador bayesiano para cenários diversos (alguns deles extremos).

Para o contexto deste trabalho, entretanto, a distribuição a priori mais adequada seria a uniforme, tendo em vista que ela reflete o desconhecimento prévio sobre o parâmetro de interesse (RSR). Os resultados mostraram, entretanto, que para SFT, o estimador baseado na equação 7 apresentou performance superior ou igual a  $U(0,100)$  nos dois cenários analisados ( $RSR > 0$  e  $RSR = 0$ ). Desta forma, o estimador “Analít. (SFT)” foi escolhido para a estimação de RSR quando esta se der por SFT.

Já em relação à MSC, foi verificado que o estimador analítico (“Analít. (MSC)”) apresentou um desempenho inferior a  $U(0,100)$  nos dois casos analisados ( $RSR > 0$  e  $RSR = 0$ ). Desta forma, a distribuição a priori uniforme foi a escolhida para MSC.

A partir dessa seleção, foi realizada a sobreposição das performances dos estimadores de “Analít. (SFT)” e  $U(0,100)$  (para a MSC), cujas curvas são apresentadas na Figura 30, a seguir.

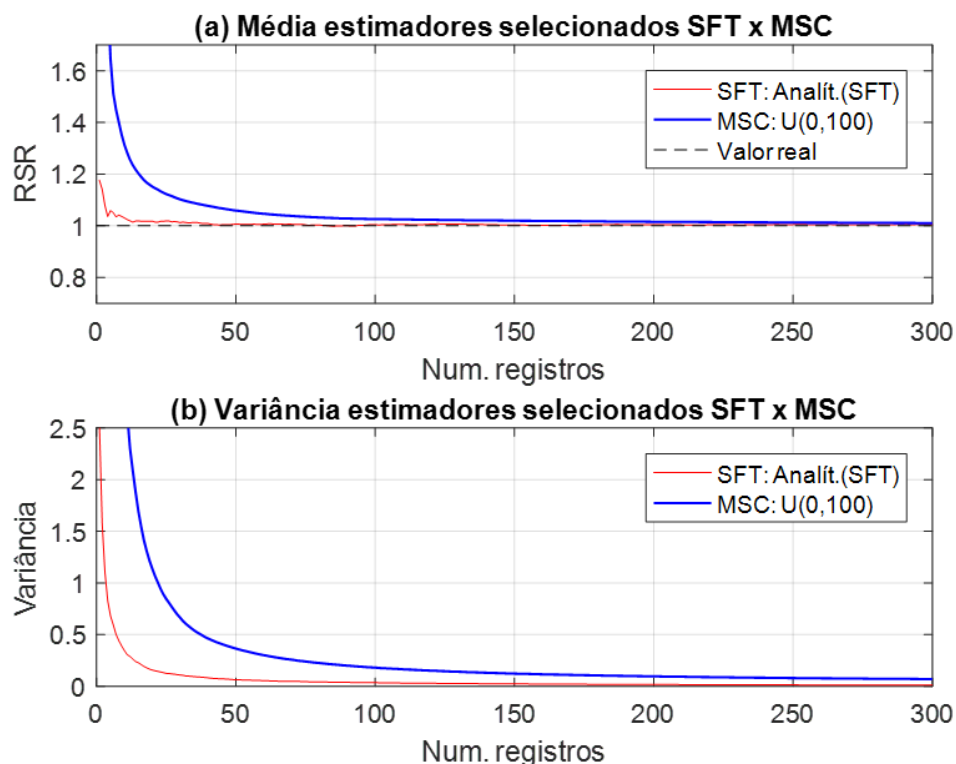


Figura 30 – Performances dos estimadores com melhor desempenho para SFT e MSC. A curva azul representa o estimador “Analít. (SFT)” e a curva vermelha representa o estimador a partir da distribuição a priori uniforme ( $U(0,100)$ ) para a MSC. (a) Média; (b) Variância.

Fonte: Dados da pesquisa.

A Figura 30 (a) mostra a evolução da média, enquanto a Figura 30 (b) apresenta o comportamento da variância dos estimadores. É possível verificar que o estimador escolhido para SFT é o que converge mais rapidamente tanto em relação à média quanto para a variância, sobretudo se considerado o intervalo até a centésima iteração (que corresponde ao número de registros ASSR disponíveis no banco de dados analisado).

Os achados apresentados na Figura 30 (a) evidenciam que, embora tenham sido os estimadores que apresentaram os melhores desempenhos para cada técnica (“Analít. (SFT)” para SFT e  $U(0,100)$  para a MSC), a convergência entre eles ocorre, aproximadamente, após 200 iterações. Desta forma, até que esse número de iterações seja atingido, os valores de RSR obtidos por  $U(0,100)$  estariam superestimados em relação à “Analít. (SFT)” (e também em relação ao valor real do parâmetro). Essa diferença nas estimativas afetaria diretamente o desempenho dos detectores, haja vista que tanto PD quanto PE dependem da RSR. Isso, portanto, comprometeria a comparação entre as técnicas SFT e MSC, uma vez que não seria possível determinar se uma eventual diferença de performance entre elas se deu em função da natureza de cada técnica ou se foi devido às diferentes estimativas obtidas para a RSR ao longo do processamento dos registros. Desta forma, para viabilizar a comparação entre as performances das técnicas SFT e MSC na análise dos sinais ASSR, foi escolhido apenas o método “Analít. (SFT)” para a estimação da RSR, tendo em vista que sua convergência para o valor real foi melhor que aquela apresentada por  $U(0,100)$ .

### 4.3 APLICAÇÃO EM REGISTROS ASSR

Esta seção traz os resultados encontrados a partir da aplicação dos detectores NP e bayesiano (para as técnicas SFT e MSC) nos registros ASSR. O procedimento adotado no processamento dos dados se baseou nos resultados encontrados nas seções anteriores. Desta forma, o detector bayesiano foi analisado considerando a estratégia de se manter o valor da probabilidade a priori fixo (“ $P(H0) = 0,5$ ”) e também aquela que considera o menor valor possível para  $P(H0)$  [“ $P(H0)$  min”]. Conforme verificado na seção 4.1, as estratégias “ $P(H0)$  max” e “PE max” não foram avaliadas em função das razões apresentadas anteriormente. O detector NP, por sua vez, foi calculado considerando um nível de significância de 5% e a estimação da RSR, conforme esclarecido anteriormente, foi realizada a partir da equação 7.

Os gráficos da Figura 31 apresentam os resultados da SFT quando aplicada aos dados de um dos indivíduos submetido ao estímulo de intensidade 50 dB<sub>SPL</sub>. Os gráficos (a) e (b) apresentam, respectivamente, a execução de SFT em um bin com resposta (78,12 Hz) e outro sem resposta (107,42 Hz). As linhas vermelhas tracejadas correspondem à evolução temporal do teste ( $\phi(f_0)$ ) à medida em que mais registros são utilizados na promediação temporal (incremento da RSR proporcional ao número de registros), enquanto as linhas

em azul correspondem ao limiar do detector NP. Para o detector bayesiano, as linhas vermelhas sólidas representam o limiar para “ $P(H_0) = 0,5$ ”, enquanto a linha preta sólida indica o valor crítico para a estratégia “ $P(H_0)$  min”.

Os gráficos (c) e (d) trazem as curvas de desempenho encontradas para os dois bins analisados ((c) 78,12 Hz e (d) 107,42 Hz). Em azul, é apresentada a curva da probabilidade de detecção para o detector NP. Para o detector bayesiano, são mostradas as curvas PA relacionadas às duas estratégias utilizadas: em vermelho, a curva de PA para “ $P(H_0) = 0,5$ ”; e em preto, a probabilidade de acerto para “ $P(H_0)$  min”.

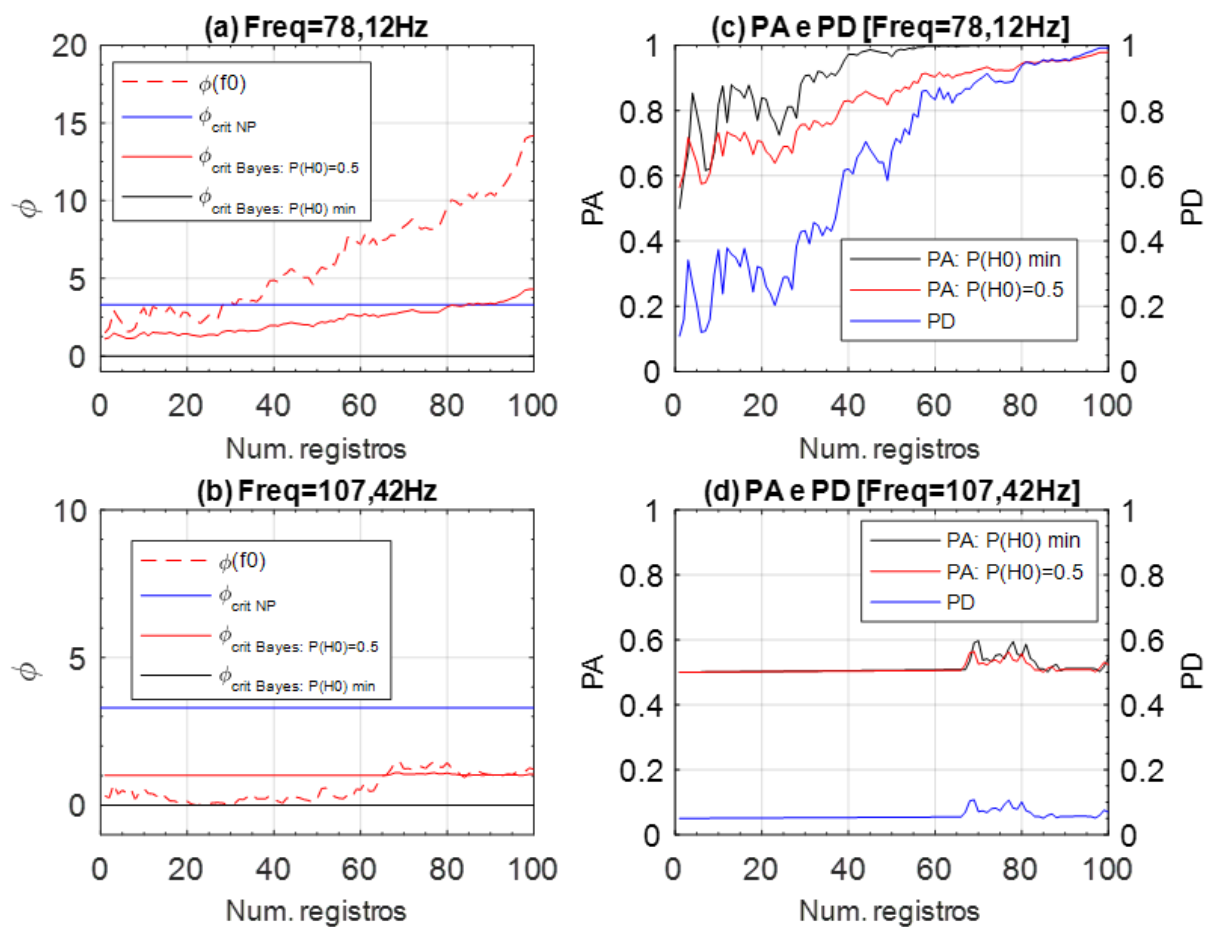


Figura 31 – Desempenho dos detectores NP e bayesiano aplicados em registros ASSR para SFT. Evolução de um bin (vermelho tracejado) com resposta (a) e um bin sem resposta (b) em relação aos limiares NP (azul) e bayesiano (vermelho sólido [PA: “ $P(H_0) = 0,5$ ”] e preto sólido [PA: “ $P(H_0)$  min”]), em função do número de trechos processados; (c) e (d): Performances dos detectores NP (PD) e bayesiano (PA) para o bin com resposta e sem resposta, respectivamente.

Fonte: Dados da pesquisa.

Para o bin com resposta (78,12 Hz, Figura 31 (a)), percebe-se que SFT apresenta uma tendência de crescimento, resultante do aumento da RSR causada pela promediação temporal. Esse gráfico também mostra que  $\phi_{crit NP}$  é ultrapassado de forma significativa após o processamento de, aproximadamente, 30 registros de EEG, instante no qual o

detector NP decide por  $H1$ . Para o detector bayesiano é possível ver que os limiares das duas estratégias (“ $P(H0)$  min” e “ $P(H0) = 0,5$ ”) são ultrapassados por  $\phi(f_0)$  após o processamento de poucos registros, indicando a detecção de respostas a partir das primeiras iterações.

Com relação ao desempenho dos detectores para esse bin (Figura 31 (c)), tanto PD quanto as curvas PA apresentaram comportamento crescente, com algumas oscilações que refletem as variações de  $\phi(f_0)$  ao longo das iterações. Após o processamento dos 100 registros de EEG, o detector NP apresentou  $PD \approx 0,99$ . O detector bayesiano, por sua vez, apresentou um desempenho superior para a estratégia “ $P(H0)$  min” em relação à “ $P(H0) = 0,5$ ”. Pode ser visto que “ $P(H0)$  min” atinge um PA de 100% com, aproximadamente, 60 registros analisados, enquanto “ $P(H0) = 0,5$ ” não chega a esse patamar ao final da centésima iteração.

O gráfico referente ao bin sem resposta (107,42 Hz, Figura 31 (b)) mostra que  $\phi(f_0)$  oscila abaixo de  $\phi \approx 1$  ao longo da maior parte das 100 iterações, ficando, portanto, abaixo de  $\phi_{crit NP}$ , o que leva o detector NP a decidir pela hipótese nula. O detector bayesiano implementado para “ $P(H0) = 0,5$ ” apresenta um valor crítico que se mantém acima de  $\phi(f_0)$ , o que também sugere a decisão pela hipótese nula. Já para estratégia “ $P(H0)$  min”, há decisão a favor da hipótese alternativa a partir da primeira iteração, uma vez que  $\phi_{crit Bayes: P(H0) min} = 0$ .

A curva de desempenho do detector NP para o bin sem resposta (Figura 31 (d)) mostra que PD se mantém, como esperado, próximo da taxa de falsos positivos ( $PD = 0,05$ ), refletindo o baixo valor de  $\phi(f_0)$ . No caso do detector bayesiano, nota-se que, ao longo das iterações, as duas estratégias resultaram em curvas PA similares entre si e que apresentaram baixas performances, se mantendo em  $PA = 0,50$  ao longo de quase todas as iterações, como esperado para a ausência de resposta.

A Figura 32 traz os achados oriundos da aplicação da MSC sobre os mesmos registros.

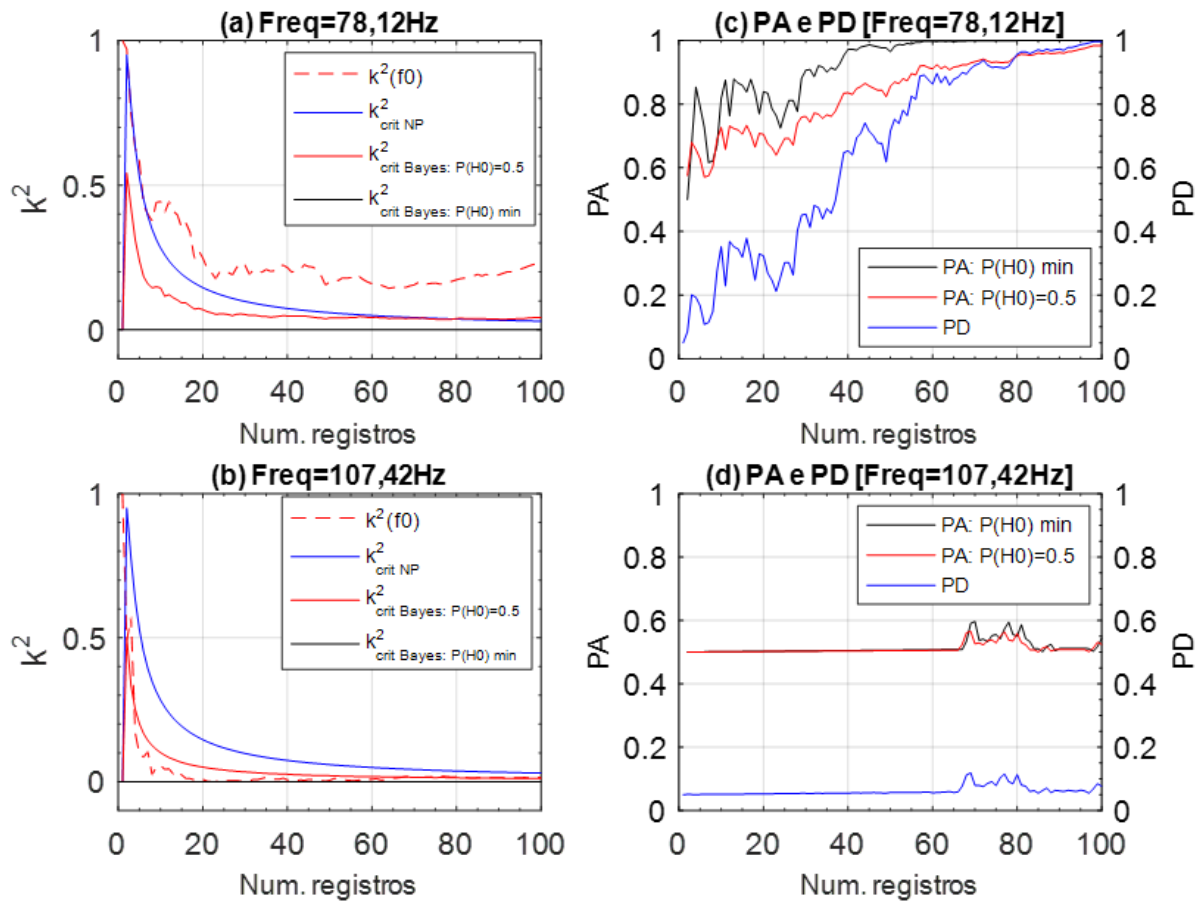


Figura 32 – Desempenho dos detectores NP e bayesiano aplicados em registros ASSR para MSC. Evolução de um bin (vermelho tracejado) com resposta (a) e um bin sem resposta (b) em relação aos limiares NP (azul) e bayesiano (vermelho sólido [PA: “ $P(H_0) = 0,5$ ”] e preto sólido [PA: “ $P(H_0) min$ ”]), em função do número de trechos processados; (c) e (d): Performances dos detectores NP (PD) e bayesiano (PA) para o bin com resposta e sem resposta, respectivamente.

Fonte: Dados da pesquisa.

De maneira análoga a SFT, os gráficos (a) e (b) (Figura 32) trazem a evolução de  $k^2(f_0)$  (vermelho tracejado) referentes a um bin com resposta e outro sem respostas, respectivamente, enquanto os gráficos (c) e (d) (Figura 32) refletem as performances encontradas para esses dois bins.

É possível verificar que na MSC o limiar de NP ( $k^2_{crit NP}$ ) inicia-se em seu valor máximo e passa a diminuir à medida que mais registros são avaliados (Figura 32 (a) e (b)). Isso se deve ao fato da hipótese  $H_0$  para a MSC ser parametrizada pelo número de registros. O limiar  $k^2_{crit Bayes: P(H_0)=0,5}$  também apresenta comportamento decrescente nas primeiras iterações, porém tende a se estabilizar em torno de um patamar cujo valor irá depender da RSR presente no sinal analisado. Se for uma resposta, este patamar será proporcional à RSR. Contudo, se for um ruído, o valor de  $k^2_{crit Bayes: P(H_0)=0,5}$  tenderá assintoticamente para zero (uma vez que nesse caso  $RSR=0$ ), conforme pode ser visto na linha vermelha sólida da Figura 32 (b). Já o limiar  $k^2_{crit Bayes: P(H_0) min}$ , assim como em



SFT, se manterá em zero.

Em relação aos desempenhos, é possível observar entre os gráficos (c) e (d) da Figura 32 a mesma diferença de padrão observada para SFT, ou seja, as curvas PA e PD referentes a presença de resposta apresentam comportamento crescente (Figura 32 (c)). Já as curvas relativas ao ruído (Figura 32 (d)) se mantêm aproximadamente constantes ( $PA \approx 0,50$  e  $PD \approx 0,05$ ) em seus respectivos patamares esperados.

A fim de se destacar a semelhança existente entre as técnicas SFT e MSC, a Figura 33 e a Figura 34 apresentam, respectivamente, a sobreposição das curvas de ambas as técnicas para a presença de resposta (apresentadas na Figura 31 (c) e Figura 32 (c)) e quando há somente ruído (gráficos apresentados nas Figura 31 (d) e Figura 32 (d)).




Figura 33 – Sobreposição das curvas de desempenho quando há respostas (PD [azul], PA: “ $P(H_0)$  min” [preto] e PA: “ $P(H_0) = 0,5$ ” [vermelho]) para SFT (tracejadas) e para MSC (sólidas).

Fonte: Dados da pesquisa.




Figura 34 – Sobreposição das curvas de desempenho quando não há respostas (PD [azul], PA: “ $P(H_0)$  min” [preto] e PA: “ $P(H_0) = 0,5$ ” [vermelho]) para SFT (tracejadas) e para MSC (sólidas).

Fonte: Dados da pesquisa.

As curvas tracejadas em ambas as figuras (Figura 33 e Figura 34) indicam as performances para SFT, enquanto as linhas sólidas representam a MSC. É possível verificar que os desempenhos alcançados para as duas técnicas (SFT e MSC) ficaram muito próximos entre si, (considerando cada tipo de detector analisado [PD, “PA:  $P(H_0) = 0,5$ ” e “PA:  $P(H_0)$  min”]), tanto para a presença de uma resposta (Figura 33) quanto para o ruído apenas (Figura 34). A fim de se explorar os demais registros ASSR disponíveis, foi realizado o levantamento de PD e PA de todos os indivíduos, levando-se em consideração as respostas no bin 78,12 Hz, para todas as intensidades sonoras. As Tabelas 2 e 3 apresentam, respectivamente, os achados para SFT e MSC após a centésima iteração. Os valores apresentados nas tabelas se referem aos desempenhos em relação às estratégias analisadas. Desta forma, as colunas “PA:  $P(H_0)$  min”, “PA:  $P(H_0) = 0,5$ ” e “PD” trazem, respectivamente, os resultados do detector bayesiano para “ $P(H_0)$  min” e “ $P(H_0) = 0,5$ ” e do detector NP.

Tabela 2 – Desempenho (em %) dos detectores NP (PD) e bayesiano (PA) de todos os indivíduos e para todas as intensidades, referente ao SFT. “ $PA_{P(H0) \min}$ ” e “ $PA_{P(H0)=0,5}$ ” representam as performances do detector bayesiano para as estratégias “ $P(H0) \min$ ” e “ $P(H0) = 0,5$ ”, respectivamente.

Sujeito	20 dB <sub>SPL</sub>			30 dB <sub>SPL</sub>			40 dB <sub>SPL</sub>			50 dB <sub>SPL</sub>		
	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD
1	52	52	-	99	88	76	100	100	100	100	100	100
2	99	88	77	100	100	100	100	100	100	100	100	100
3	50	-	-	100	95	94	100	100	100	100	100	100
4	50	-	-	51	-	-	79	66	-	80	68	-
5	87	73	42	100	97	98	100	99	100	100	100	100
6	91	76	43	98	85	68	100	94	92	100	98	100
7	50	-	-	100	99	100	100	100	100	100	100	100
8	99	85	68	100	99	100	100	100	100	100	100	100
9	55	-	-	100	87	72	100	94	90	100	100	100

Fonte: Dados da pesquisa

Nota: “-” indica que não houve detecção (respostas abaixo do limiar de decisão).

Tabela 3 – Desempenho (em %) dos detectores NP (PD) e bayesiano (PA) de todos os indivíduos e para todas as intensidades, referente à MSC. “ $PA_{P(H0) \min}$ ” e “ $PA_{P(H0)=0,5}$ ” representam as performances do detector bayesiano para as estratégias “ $P(H0) \min$ ” e “ $P(H0) = 0,5$ ”, respectivamente.

Sujeito	20 dB <sub>SPL</sub>			30 dB <sub>SPL</sub>			40 dB <sub>SPL</sub>			50 dB <sub>SPL</sub>		
	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD	$PA_{P(H0) \min}$	$PA_{P(H0)=0,5}$	PD
1	52	52	-	99	89	81	100	100	100	100	100	100
2	99	89	81	100	100	100	100	100	100	100	100	100
3	50	-	-	100	95	96	100	100	100	100	100	100
4	50	-	-	51	-	-	79	66	-	80	68	-
5	87	73	41	100	97	99	100	100	100	100	100	100
6	91	76	48	98	86	73	100	94	94	100	98	100
7	50	-	-	100	99	100	100	100	100	100	100	100
8	99	86	73	100	99	100	100	100	100	100	100	100
9	55	-	-	100	87	77	100	94	93	100	100	100

Fonte: Dados da pesquisa

Nota: “-” indica que não houve detecção (respostas abaixo do limiar de decisão).

Os resultados apresentados nas Tabelas 2 e 3 mostram que os desempenhos de SFT e MSC foram semelhantes, corroborando com os resultados de simulação (Figura 25) e aqueles apresentados na Figura 33. A maior divergência entre as Tabelas 2 e 3 ocorreu em PD para as intensidades de 20 dB<sub>SPL</sub> (indivíduos #2, #5, #6 e #7) e 30 dB<sub>SPL</sub> (indivíduos #1, #3, #5, #6 e #9). Além de serem em maior quantidade, as divergências em PD foram também aquelas que apresentaram a maior discrepância entre os valores. Contudo, a maior diferença observada entre os resultados das duas Tabelas foi de 5 pontos percentuais (por exemplo, a divergência para o indivíduo #8 em 20 dB<sub>SPL</sub>, que teve PD=68% na Tabela 2 (SFT) e PD=73% na Tabela 3 (MSC)). De um modo geral, houve divergências em 16 dos 108 valores apresentados em cada tabela, o que resulta em, aproximadamente, 15% do total. Além disso, as discrepâncias nos valores ficaram em média próximas a 3 pontos percentuais. Os resultados nos quais houve divergências estão destacados na Tabela 3. Note-se que na grande maioria desses casos os valores são superiores para a MSC.

Por outro lado, é possível verificar similaridades nos dados presentes nas duas tabelas. Para a intensidade mais baixa (20 dB<sub>SPL</sub>), a abordagem NP não detectou respostas

de cinco indivíduos (#1, #3, #4, #7 e #9). A abordagem bayesiana, por sua vez, deixou de detectar respostas de quatro indivíduos (#3, #4, #7 e #9) quando foi utilizada a estratégia de se manter constante a informação a priori (“ $P(H0) = 0,5$ ”). Para a estratégia “ $P(H0)$  min” houve detecção de resposta para todos os indivíduos. Isso se deve ao fato de o limiar de decisão para essa estratégia ser igual a zero. Deve-se ressaltar, entretanto, que embora tenha havido detecção de respostas dos nove indivíduos para “ $P(H0)$  min”, a probabilidade de acerto encontrada para os indivíduos #3, #4 e #7 foi  $PA_{P(H0) \min} = 50\%$ , o que, para essa estratégia, representa o mesmo desempenho observado quando não há respostas evocadas (como mostrados pelos gráficos da Figura 34). Para as demais intensidades (30 dB<sub>SPL</sub>, 40 dB<sub>SPL</sub> e 50 dB<sub>SPL</sub>), apenas o indivíduo #4 não teve resposta detectada por pelo menos uma das estratégias.

Em relação à performance, observa-se que nos casos em que houve detecção para todas as abordagens (sobretudo na intensidade sonora de 20 dB<sub>SPL</sub>, indivíduos #2 e #8), o detector NP apresentou performance inferior ao bayesiano, se levado em consideração que ambos os detectores têm como performance ideal o índice 100%. Quando comparadas as duas abordagens bayesianas, verifica-se que a estratégia “ $P(H0)$  min” apresentou performance superior à “ $P(H0) = 0,5$ ”, refletindo os achados descritos na Figura 24. Constata-se também que os desempenhos de todos os detectores melhoram à medida que a intensidade sonora aumenta, chegando à performance máxima em, aproximadamente, 90% dos indivíduos para a intensidade de 50 dB<sub>SPL</sub>.

## 5 DISCUSSÃO

Neste trabalho foram desenvolvidos detectores por meio da abordagem bayesiana, para o teste espectral F (SFT) e para a magnitude quadrática da coerência (MSC), os quais foram comparados com os detectores de NP. Além disso, para viabilizar a aplicação desses detectores em registros ASSR, foram avaliados também alguns estimadores para a relação sinal/ruído (RSR).

A curva de desempenho encontrada para o detector NP (Figura 9) foi muito próxima aos achados de Miranda de Sá et al. (2009) e Felix et al. (2018), que também utilizaram o teste espectral F para a detecção de potenciais evocados em regime permanente. A apresentação do intervalo de confiança associada as estimativas de  $\phi(f_0)$ , fornece uma informação adicional em relação ao desempenho do detector NP, auxiliando na interpretação dos dados e na tomada de decisão.

Em relação ao detector bayesiano, verificou-se que a capacidade de escolha para as probabilidades a priori confere inúmeras possibilidades para a condução do teste de hipóteses (como mostrado nas curvas de contorno referente à PE). Entretanto, escolhas arbitrárias para as  $P(H_0)$  (ou  $P(H_1)$ ) podem resultar em situações que pouco contribuem para a detecção de respostas. É o caso, por exemplo, do detector implementado a partir da escolha dos valores máximos de  $P(H_0)$  (“ $P(H_0)$  max”). Conforme observado nas simulações para SFT e MSC (Figura 14 e Figura 22, respectivamente), este detector foi o que apresentou melhor desempenho teórico, entretanto, os elevados valores críticos associados a essa estratégia resulta na não detecção de respostas mesmo quando há uma RSR elevada. Observou-se também que a opção por manter “ $P(H_0) = 0,5$ ” ao longo de todo o processo de detecção apresenta uma performance muito próxima ao pior desempenho possível para o detector, cujos valores (“PE max”) podem ser encontrados pelo critério minimax, conforme mostrado na Figura 23.

Desta forma, dentre os cenários analisados, o que se mostrou mais promissor foi aquele no qual são escolhidos os menores valores possíveis para  $P(H_0)$  (“ $P(H_0)$  min”), haja vista que ele possibilita a detecção em baixos níveis de RSR e apresenta uma performance consideravelmente melhor em relação à estratégia de “ $P(H_0) = 0,5$ ”. Apesar dos resultados encontrados indicarem boas perspectivas, o detector bayesiano ainda demanda investigações mais aprofundadas que considerem outras estratégias de escolha para as probabilidades a

priori.

A relação entre as curvas de desempenho dos detectores apresentada na Figura 24 (a) (SFT) e na Figura 24 (b) (MSC) mostrou que o detector bayesiano, mesmo em sua pior performance, se aproxima do ponto de operação ideal, i.e., probabilidade de acerto de 100% (PA=100%), mais rápido que o detector NP, que visa uma probabilidade de detecção de 100% (PD=100%). Deve-se salientar, entretanto, que as abordagens NP e bayesiana são fundamentadas em diferentes interpretações acerca de inferência estatística (KAY, 1998) e, portanto, deve-se ter cautela ao buscar comparações entre o desempenho dos detectores, uma vez que PD e PA representam medidas distintas. Desta forma, apesar das primeiras indicações de comparação aqui apresentadas, deve-se realizar uma investigação mais aprofundada sobre possíveis formas de relacionamento entre os dois métodos. Outro ponto que demanda uma investigação mais aprofundada relaciona-se à definição de um critério de parada para o detector bayesiano. Os resultados referentes a aplicação de SFT e MSC em registros ASSR (Figura 31 e Figura 32, respectivamente) mostram que o fato de uma amostra ser maior que o valor crítico não é, necessariamente, o único indício que deve ser considerado para a tomada de decisão a favor da hipótese alternativa ( $H_1$ ). É o que ocorre, por exemplo, quando se escolhe o menor valor possível para  $P(H_0)$  (“ $P(H_0)$  min”). Os resultados apresentados nos gráficos (a) e (b) da Figura 14 e da Figura 22 mostram que para essa estratégia os valores críticos de SFT e MSC são nulos ( $\phi_{crit Bayes} = 0$  e  $k^2_{crit Bayes} = 0$ , respectivamente). Como o valor das amostras para ambas as técnicas sempre será maior que zero, o detector tenderá a decidir por  $H_1$  a partir da primeira iteração, ainda que o sinal analisado seja um ruído (Figura 31 (b) e Figura 32(b)). A análise dos gráficos de desempenho, entretanto, mostram que, quando não há respostas evocadas (Figura 31 (d) e Figura 32 (d)), o valor da “PA[ $P(H_0)$  min]” se mantém próximo à 50%. Por outro lado, quando há respostas evocadas, o valor de “PA[ $P(H_0)$  min]” tende ao nível máximo ( $PA = 1$ ) à medida que a RSR aumenta (Figura 31 (c) e Figura 32 (c)). Portanto, para a estratégia “ $P(H_0)$  min”, a decisão a respeito da presença ou ausência de respostas evocadas deve ser baseada no valor de PA e não apenas na comparação dos valores de  $\phi(f_0)$  e  $\phi_{crit Bayes}$  [ ou  $k^2(f_0)$  e  $k^2_{crit Bayes}$  no caso da MSC]. Por esse motivo, é preciso que seja investigada a possibilidade de definição de patamares para PA (ou PE) que sirvam de referência para a tomada de decisão.

Em relação às duas técnicas ORD investigadas, foram levantadas as curvas de desempenho considerando uma ampla faixa de variação nos parâmetros que caracterizam cada uma. Verificou-se, conforme esperado, a melhoria nas performances à medida que aumentam os valores de RSR,  $M$  (bins) [SFT] e  $N$  (janelas) [MSC]. Em relação à SFT constatou-se, entretanto, que o aumento de  $M$  a partir de  $M = 12$  não resulta em melhoras expressivas nas curvas de desempenho. Esses resultados foram compatíveis com os achados de Miranda de Sá et al. (2009), que também investigaram o uso do teste espectral F, com abordagem NP, em aplicações a potenciais evocados. Uma análise da equação 1 permite

constatar que  $M$  está relacionado à estimativa da potência do ruído. Desta forma, quanto maior for o valor de  $M$ , mais precisa será essa estimativa. Contudo, o ganho de performance de SFT apresenta forte dependência em relação ao parâmetro de não centralidade, que é função apenas da  $RSR$  ( $\lambda = 2.RSR$ ). Conseqüentemente, o incremento de  $M$  a partir de  $M = 12$ , traz pouca relevância a SFT, ou seja, as distribuições de  $H0$  ( $F_{2,2M}$ ) e  $H1$  ( $F'_{2,2M}(\lambda)$ ) são pouco afetadas para  $M > 12$ .

Já as curvas de desempenho para MSC do detector NP corroboraram com os achados de Miranda de Sá e Infantosi (2002). A análise realizada na seção 4.1.4 mostrou que, em termos de performances, as duas técnicas são semelhantes. Conforme apresentado na Figura 25, verificou-se que a performance de SFT é muito próxima à de MSC quando são utilizados mais de 12 componentes espectrais na estimação do ruído ( $M \geq 12$ ). Esses achados vão de encontro ao que concluiu Dobie e Wilson (1996), que demonstraram analiticamente a relação existente entre esses dois métodos com NP. O fato de MSC utilizar a informação de amplitude e fase para fazer a detecção sugere que sua performance seria superior a de SFT, que se vale apenas da amplitude. Contudo, o cálculo de SFT envolve a promediação de registros que estão sincronizados com o estímulo, o que, indiretamente, leva em consideração a informação de fase.

Com relação aos estimadores, verificou-se que a convergência assintótica de todos os métodos avaliados (bayesiano, MLE e analítico) mostra que a informação a priori apresenta uma relevância gradualmente menor à medida que mais amostras são disponibilizadas. Ressalta-se, contudo, que para o contexto deste trabalho é de grande interesse que o estimador convirja o mais rápido possível para o valor real, pois caso contrário o tempo de aquisição de dados pode se tornar longo demais, inviabilizando a aplicação do ASSR na rotina médica.

Por isso, neste trabalho buscou-se verificar como a probabilidade a priori pode afetar essa convergência, principalmente em relação às primeiras iterações. As distribuições a priori com variância pequena [ $N(RSR = 1; \sigma^2 = 0,001)$  e  $N(RSR = 1,5; \sigma^2 = 0,001)$ ], por exemplo, indicam (do ponto de vista bayesiano) situações nas quais há grande convicção a respeito do valor do parâmetro a ser estimado. Contudo, elas representam situações extremas. Na primeira, a média era de fato o valor real quando havia uma resposta, enquanto na segunda, o valor  $\mu = 1,5$  ilustra um cenário no qual há convicção no valor da  $RSR$ , mas o valor esperado está distante do valor real (considerando as proporções utilizadas nesse trabalho). Os resultados mostraram como essas duas situações afetam consideravelmente a performance do estimador, tendo em vista que elas resultaram na melhor e pior performances, respectivamente. Verificou-se também como as performances são afetadas pela mudança na variância. A Figura 26 mostrou que há uma melhora expressiva no desempenho da distribuição a priori normal com média  $\mu = 1,5$  quando a variância passa de  $\sigma^2 = 0,001$  para  $\sigma^2 = 1$ . Por outro lado, há uma perda de performance

quando essa mesma mudança acontece em relação à distribuição normal com média  $\mu = RSR = 1$ . Embora tenha sido possível observar expressivas diferenças na performance da distribuição normal em função dos valores de  $\mu$  e  $\sigma^2$ , é necessária uma investigação mais detalhada sobre influência desses parâmetros na convergência do estimador.

A distribuição a priori uniforme, por sua vez, representa a situação na qual não se tem conhecimento algum (ou não se deseja expressar conhecimento prévio) a respeito do parâmetro a ser estimado (priori não informativa). Contudo, seu desempenho intermediário em relação às demais lhe credencia como uma boa opção de escolha, tendo em vista a falta de informação prévia sobre aquilo que se deseja estimar.

Ainda em relação a distribuição a priori uniforme, verificou-se que seu desempenho converge rapidamente com o estimador de máxima verossimilhança (MLE). Esses achados corroboram com a literatura (KAY, 1993), que mostra que o estimador MAP para a distribuição a priori uniforme opera na maximização da função de verossimilhança assim como MLE. Por isso ele recebe a denominação de “MLE bayesiano”. Kay (1993) ressalta, entretanto, que apesar de realizarem a mesma operação nos dados, MLE e MLE bayesiano são inerentemente distintos.

Se for considerado que o número de amostras tende ao infinito, então a convergência do estimador MAP com MLE valerá para qualquer distribuição a priori (LEVY, 2008), como pode ser visto nos resultados da seção 4.2. Consequentemente, os estimadores MAP utilizados serão consistentes, assintoticamente eficientes e assintoticamente gaussianos.

As diferenças observadas no padrão de convergência das curvas de performance entre SFT e MSC para um mesmo cenário ( $RSR=1$  [Figura 26 e Figura 28] ou  $RSR=0$  [Figura 27 e Figura 29]) era esperada, haja vista que as funções de verossimilhança que descrevem o comportamento estatístico das amostras são distintas. Fica nítido, por exemplo, que a convergência das estimativas para a MSC quando  $RSR=0$  (Figura 29) é mais acentuada que a convergência para SFT para o mesmo cenário (Figura 27). Isso ocorre porque a função de verossimilhança de MSC para ruído é parametrizada pelo número ( $N$ ) de registros analisados ( $p(k^2; H_0) \sim \text{beta}(1, N - 1)$ ). Isso faz com que, a cada iteração, essa distribuição seja atualizada e o incremento de  $N$  causa o seu deslocamento em direção a zero. Consequentemente, a moda da distribuição a posteriori, bem como a máxima verossimilhança acontecerá nas proximidades da origem. O mesmo não ocorre para SFT, uma vez que a distribuição para a hipótese de ruído é parametrizada apenas pelo número de bins ( $M$ ) utilizados na estimação do ruído ( $\hat{\phi}(f_0) \Big|_{H_0} \sim F_{2,2M}$ ), não sendo, portanto, influenciada pelo número de registros. Consequentemente, a convergência para  $RSR=0$  será mais lenta.

Dentre todos os estimadores avaliados, o melhor desempenho encontrado foi para aquele baseado na equação 7, no qual a estimativa se deu a partir da equação do valor esperado da distribuição F não central. Ressalta-se, contudo, que o foco principal deste



trabalho foi a construção e compreensão das performances de detectores a partir da abordagem bayesiana. Desta forma, as investigações acerca de estimadores realizadas nesse estudo buscaram compreender, de forma geral, a influência que a informação a priori tem no processo de estimação e a relação desta abordagem em comparação a outros tipos de estimadores, como MLE. Portanto, o estudo acerca de estimadores deve ser aprofundado, uma vez que a estimação da RSR é determinante para o levantamento das performances dos detectores.

Em relação à identificação do potencial evocado auditivo nos sinais de EEG, os resultados encontrados após a análise das respostas ASSR (Figura 31 e Figura 32; Tabela 2 e Tabela 3) mostraram que todos os detectores apresentaram as melhores performances para estímulos com intensidades mais altas, corroborando como os achados descritos por Picton, Van Roon e John (2007). Verificou-se também que o detector bayesiano implementado com “ $P(H0) = 0,5$ ” apresentou um desempenho inferior em relação à “ $P(H0)$  min” e que ambos se aproximaram da performance ótima mais rápido que o detector NP, refletindo os resultados observados nas simulações. Além disso, constatou-se mais uma vez que as performances dos detectores para SFT e MSC são semelhantes, como pôde ser observado na similaridade existente entre os dados apresentados nas Tabelas 2 e 3.

## 6 CONCLUSÃO

Neste trabalho foi utilizada a abordagem bayesiana na construção de detectores para aplicação em potenciais evocados auditivos a partir das técnicas SFT e MSC. Para tanto, foi realizado também um estudo visando a exploração de métodos clássicos e bayesianos destinados à estimação da RSR.

Os resultados mostraram que o detector bayesiano pode ser implementado de inúmeras maneiras, tendo em vista a liberdade de escolha para atribuição de custos às decisões que podem ser tomadas e para as probabilidades de ocorrência de cada uma das hipóteses concorrentes. Verificou-se que a estratégia de escolha de  $P(H0)$  tem grande influência no desempenho que será alcançado pelo detector, o que em uma aplicação real pode contribuir na redução do tempo necessário para a tomada de uma decisão. Ressalta-se, contudo, que os registros analisados neste trabalho advêm de indivíduos normo-ouvintes e que o volume de dados disponível é reduzido. Desta forma, é necessário que essa abordagem seja explorada de forma mais abrangente em relação aos potenciais evocados, para que sua performance possa ser melhor caracterizada em outros contextos como, por exemplo, no levantamento de limiares auditivos.

Em relação aos estimadores, foi novamente constatada a interferência que a informação a priori tem nos resultados que serão alcançados, sobretudo quando há um número limitado de amostras disponíveis. Tendo em vista a grande importância que a RSR tem para o levantamento do desempenho dos detectores, sugere-se que sejam realizados estudos mais aprofundados sobre a construção de estimadores bayesianos que possam se valer da informação a priori para fornecer resultados ainda mais precisos e em menor tempo. A exploração de bancos de dados contendo diversos registros ASSR poderia ser útil no levantamento de padrões, o que possibilitaria escolhas mais assertivas para as probabilidades a priori  $P(H0)$  e  $P(RSR)$  de acordo com o perfil audiológico de cada indivíduo avaliado. Outro campo promissor a ser explorado está na aplicação da abordagem bayesiana em outras técnicas ORD descritas na literatura (PSM e T<sup>2</sup>Circ), visando a abreviação do tempo necessário para a tomada de uma decisão. Isso é de grande importância para viabilizar a aplicação dos potenciais evocados na rotina médica, principalmente em triagem auditiva.

Ao longo deste trabalho foram iniciados estudos em assuntos correlatos ao tema

principal, visando possibilidades de aprimoramento dos detectores. Entre eles estão o desenvolvimento de detectores sequenciais (clássico e bayesiano) e o levantamento das performances dos detectores NP e bayesiano de forma analítica. Desta forma, como trabalhos futuros, será dada continuidade à exploração destes temas. Além disso, pretende-se investigar também como os custos ( $C_{00}$ ,  $C_{11}$ ,  $C_{01}$  e  $C_{10}$ ) devem ser definidos nas diversas aplicações clínicas do ASSR e como isso irá interferir na performance do detector bayesiano.

É importante reiterar que o principal objetivo pretendido por esse trabalho foi contribuir com a literatura por meio da caracterização de detectores bayesianos para aplicações nas técnicas SFT e MSC. Deve ser esclarecido que as abordagens clássica e bayesiana se baseiam em diferentes interpretações sobre probabilidades e, desta forma, ainda não há métricas estabelecidas que possibilitem comparações entre os respectivos desempenhos. Desta forma, o paralelo entre PD e PA estabelecido neste trabalho visou principalmente evidenciar as diferenças entre elas. Desta forma, investigações mais aprofundadas devem ser feitas de modo a explorar possíveis meios de relacioná-las, bem como verificar se no contexto dos potenciais evocados há situações nas quais o emprego de uma abordagem é mais apropriado que a outra.

## REFERÊNCIAS

- ABDO, F. I. *Estudo de Parâmetros para a Monitorização de Múltiplas Respostas Auditivas em Regime Permanente*. 2012. Dissertação (Mestrado em Engenharia Elétrica) — PPGE - Universidade Federal de Minas Gerais.
- ALSTON, C. et al. *Case studies in Bayesian statistical modelling and analysis*. UK: Wiley Online Library, 2012.
- AOYAGI, M. et al. An Application of Phase Spectral Analysis to Amplitude—Modulation Following Response. *Acta Oto-Laryngologica*, Taylor & Francis, v. 113, n. sup504, p. 82–88, 1993a.
- AOYAGI, M. et al. Optimal modulation frequency for amplitude-modulation following response in young children during sleep. *Hearing research*, Elsevier, v. 65, n. 1-2, p. 253–261, 1993b.
- BAHMER, A.; BAUMANN, U. Recording and online analysis of auditory steady state responses (ASSR) in Matlab. *Journal of neuroscience methods*, Elsevier, v. 187, n. 1, p. 105–113, 2010.
- BARNETT, V. *Comparative statistical inference*. London: John Wiley & Sons, 1999.
- BAYES, T.; PRICE, R. LII. An essay towards solving a problem in the doctrine of chances. By the late Rev. Mr. Bayes, FRS communicated by Mr. Price, in a letter to John Canton, AMFR S. *Philosophical transactions of the Royal Society of London*, The Royal Society London, n. 53, p. 370–418, 1763.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neurociências: desvendando o sistema nervoso*. 4. ed. Porto Alegre: Artmed Editora, 2017.
- BERGER, J. et al. The case for objective Bayesian analysis. *Bayesian analysis*, International Society for Bayesian Analysis, v. 1, n. 3, p. 385–402, 2006.
- BERGER, J. O. *Statistical decision theory and Bayesian analysis*. New York: Springer Science & Business Media, 2013.
- BONITA, J. et al. Time domain measures of inter-channel EEG correlations: a comparison of linear, nonparametric and nonlinear measures. *Cognitive neurodynamics*, Springer, v. 8, n. 1, p. 1–15, 2014.
- CANDY, J. V. *Bayesian signal processing: classical, modern, and particle filtering methods*. New Jersey: John Wiley & Sons, 2016. v. 54.
- CARLIN, B. P.; LOUIS, T. A. *Bayesian methods for data analysis*. FL: CRC Press, 2008.

- CAUSEVIC, E. et al. Fast wavelet estimation of weak biosignals. *IEEE Transactions on biomedical engineering*, IEEE, v. 52, n. 6, p. 1021–1032, 2005.
- CAVALCANTI, H. G. et al. Overview of newborn hearing screening programs in Brazilian maternity hospitals. *Brazilian journal of otorhinolaryngology*, SciELO Brasil, v. 80, n. 4, p. 346–353, 2014.
- CONGDON, P. *Applied bayesian modelling*. UK: John Wiley & Sons, 2014. v. 595.
- COURCHESNE, E. et al. Autism: processing of novel auditory information assessed by event-related brain potentials. *Electroencephalography and Clinical Neurophysiology/ Evoked Potentials Section*, Elsevier, v. 59, n. 3, p. 238–248, 1984.
- DIMITRIJEVIC, A. et al. Human auditory steady-state responses to tones independently modulated in both frequency and amplitude. *Ear and hearing*, LWW, v. 22, n. 2, p. 100–111, 2001.
- DOBIE, R. A.; WILSON, M. J. Analysis of auditory evoked potentials by magnitude-squared coherence. *Ear and hearing*, v. 10, n. 1, p. 2–13, 1989.
- DOBIE, R. A.; WILSON, M. J. Objective response detection in the frequency domain. *Electroencephalography and Clinical Neurophysiology/ Evoked Potentials Section*, Elsevier, v. 88, n. 6, p. 516–524, 1993.
- DOBIE, R. A.; WILSON, M. J. A comparison of t test, F test, and coherence methods of detecting steady-state auditory-evoked potentials, distortion-product otoacoustic emissions, or other sinusoids. *The Journal of the Acoustical Society of America*, Acoustical Society of America, v. 100, n. 4, p. 2236–2246, 1996.
- DURAND, D. M. What is Neural Engineering? *J. Neural Eng.*, v. 4, n. 4, 2006.
- ELIASMITH, C.; ANDERSON, C. H. *Neural Engineering: Computation, Representation, and Dynamics in Neurobiological Systems*. London: MIT Press, 2004. 376 p. ISBN 0262550601.
- ELLSBERG, D. *Risk, ambiguity and decision*. New York: Routledge, 2015.
- FELIX, L. B. et al. Multivariate approach for estimating the local spectral F-test and its application to the EEG during photic stimulation. *Computer methods and programs in biomedicine*, Elsevier, v. 162, p. 87–91, 2018.
- FISHBURN, P. C. The axioms of subjective probability. *Statistical Science*, JSTOR, p. 335–345, 1986.
- FRANÇOIS, M. et al. Use of auditory steady-state responses in children and comparison with other electrophysiological and behavioral tests. *European annals of otorhinolaryngology, head and neck diseases*, Elsevier, v. 133, n. 5, p. 331–335, 2016.
- GALAMBOS, R.; MAKEIG, S.; TALMACHOFF, P. J. A 40-Hz auditory potential recorded from the human scalp. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 78, n. 4, p. 2643–2647, 1981.
- GAMERMAN, D.; LOPES, H. F. *Markov chain Monte Carlo: stochastic simulation for Bayesian inference*. FL: CRC Press, 2006.

- GARTHWAITE, P. H.; KADANE, J. B.; O'HAGAN, A. Statistical methods for eliciting probability distributions. *Journal of the American Statistical Association*, Taylor & Francis, v. 100, n. 470, p. 680–701, 2005.
- GATH, I.; INBAR, G. F. *Advances in processing and pattern analysis of biological signals*. Haifa: Springer Science & Business Media, 2013.
- GELFAND, A. *Essentials of audiology*. 4. ed. New York: Thieme, 2016.
- GELFAND, A. E.; SMITH, A. F. Sampling-based approaches to calculating marginal densities. *Journal of the American statistical association*, Taylor & Francis Group, v. 85, n. 410, p. 398–409, 1990.
- GIGERENZER, G.; KRAUSS, S.; VITOUCH, O. *The Null Ritual: What You Always Wanted to Know About Significance Testing but Were Afraid to Ask*. [S.l.: s.n.], 2004.
- GILKS, W.; RICHARDSON, S.; SPIEGELHALTER, D. *Markov Chain Monte Carlo in Practice*. London: Chapman and Hall., 1996.
- GREEN, P. J. et al. Bayesian computation: a summary of the current state, and samples backwards and forwards. *Statistics and Computing*, Springer, v. 25, n. 4, p. 835–862, 2015.
- HALL III, J. *eHandbook of auditory evoked responses: principles, procedures & protocols*. [S.l.]: Pretoria: Pearson, 2015.
- HARI, R. et al. Auditory evoked transient and sustained magnetic fields of the human brain localization of neural generators. *Experimental Brain Research*, Springer, v. 40, n. 2, p. 237–240, 1980.
- HEO, J. et al. Music and natural sounds in an auditory steady-state response based brain–computer interface to increase user acceptance. *Computers in biology and medicine*, Elsevier, v. 84, p. 45–52, 2017.
- HERDMAN, A. T.; STAPELLS, D. R. Thresholds determined using the monotic and dichotic multiple auditory steady-state response technique in normal-hearing subjects. *Scandinavian audiology*, Taylor & Francis, v. 30, n. 1, p. 41–49, 2001.
- HJORT, N. L. et al. *Bayesian nonparametrics*. New York: Cambridge University Press, 2010. v. 28.
- HOFF, P. D. *A first course in Bayesian statistical methods*. New York: Springer, 2009. v. 580.
- HONIG, L. S.; RAMSAY, R. E.; SHEREMATA, W. A. Event-related potential P300 in multiple sclerosis: relation to magnetic resonance imaging and cognitive impairment. *Archives of neurology*, American Medical Association, v. 49, n. 1, p. 44–50, 1992.
- HUMES, L.; BESS, F. *Audiology and communication disorders: An overview*. 1. ed. [S.l.]: Lippincott Williams & Wilkins, 2008.
- JAFARZADEH, S.; JALAIE, B.; KAMALI, M. A comparison of thresholds in auditory steady-state response with pure tone audiometry in subjects with normal hearing and those with mild and moderate sensorineural hearing loss. *Bimonthly Audiology-Tehran University of Medical Sciences*, Bimonthly Audiology-Tehran University of Medical Sciences, v. 17, n. 1, p. 53–62, 2008.

- JAYNES, E. T. Prior probabilities. *IEEE Transactions on systems science and cybernetics*, IEEE, v. 4, n. 3, p. 227–241, 1968.
- JOHN, M.; DIMITRIJEVIC, A.; PICTON, T. Efficient stimuli for evoking auditory steady-state responses. *Ear and hearing*, LWW, v. 24, n. 5, p. 406–423, 2003.
- JOHN, M.; PICTON, T. Human auditory steady-state responses to amplitude-modulated tones: phase and latency measurements. *Hearing research*, Elsevier, v. 141, n. 1-2, p. 57–79, 2000.
- JOHN, M. S.; DIMITRIJEVIC, A.; PICTON, T. W. Weighted averaging of steady-state responses. *Clinical Neurophysiology*, Elsevier, v. 112, n. 3, p. 555–562, 2001.
- JOHN, M. S.; DIMITRIJEVIC, A.; PICTON, T. W. Auditory steady-state responses to exponential modulation envelopes. *Ear and hearing*, LWW, v. 23, n. 2, p. 106–117, 2002.
- JOHN, M. S. et al. Multiple auditory steady-state responses to AM and FM stimuli. *Audiology and Neurotology*, Karger Publishers, v. 6, n. 1, p. 12–27, 2001.
- JOHN, M. S. et al. Multiple auditory steady-state responses (MASTER): stimulus and recording parameters. *Audiology*, Taylor & Francis, v. 37, n. 2, p. 59–82, 1998.
- KANDEL, E. et al. *Princípios de neurociências*. 5. ed. Porto Alegre: AMGH Editora, 2014.
- KAONGOEN, N.; JO, S. A novel hybrid auditory BCI paradigm combining ASSR and P300. *Journal of neuroscience methods*, Elsevier, v. 279, p. 44–51, 2017.
- KASS, R. E.; WASSERMAN, L. The selection of prior distributions by formal rules. *Journal of the American Statistical Association*, Taylor & Francis, v. 91, n. 435, p. 1343–1370, 1996.
- KATZ, J. et al. *Handbook of Clinical Audiology*. Philadelphia: Wolters Kluwer Health, 2014.
- KAY, S. *Fundamentals of Statistical Signal Processing: Detection theory*. USA: Prentice-Hall PTR, 1998.
- KAY, S. M. *Fundamentals of Statistical Signal Processing: Estimation Theory*. USA: Prentice-Hall, Inc., 1993.
- KIM, D.-W. et al. Classification of selective attention to auditory stimuli: toward vision-free brain–computer interfacing. *Journal of neuroscience methods*, Elsevier, v. 197, n. 1, p. 180–185, 2011.
- KROESE, D. P.; TAIMRE, T.; BOTEV, Z. I. *Handbook of monte carlo methods*. New Jersey: John Wiley & Sons, 2013. v. 706.
- KRUSCHKE, J. *Doing Bayesian data analysis: A tutorial with R, JAGS, and Stan*. [S.l.]: Academic Press, 2014.
- LAPLACE, P.; DALE, A. *Pierre-Simon Laplace Philosophical Essay on Probabilities: Translated from the fifth French edition of 1825 With Notes by the Translator*. New York: Springer, 1995. (Sources in the History of Mathematics and Physical Sciences).

- LEAMER, E. E. A Bayesian perspective on inference from macroeconomic data. *The Scandinavian Journal of Economics*, JSTOR, p. 225–248, 1991.
- LEHMANN, E. L. The Fisher, Neyman-Pearson theories of testing hypotheses: one theory or two? *Journal of the American statistical Association*, Taylor & Francis Group, v. 88, n. 424, p. 1242–1249, 1993.
- LEITE, R. T.; SIMPSON, D. M.; INFANTOSI, A. F. Comparison of techniques for objective identification of EEG responses to somatosensitive stimulation. In: IEEE. *Proceedings of 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.], 1996. v. 3, p. 980–981.
- LEUENBERGER, C.; WEGMANN, D. Bayesian computation and model selection without likelihoods. *Genetics*, Genetics Soc America, v. 184, n. 1, p. 243–252, 2010.
- LEVY, B. C. *Principles of signal detection and parameter estimation*. New York: Springer Science & Business Media, 2008.
- LINS, O. G. et al. Auditory steady-state responses to tones amplitude-modulated at 80–110 Hz. *The Journal of the Acoustical Society of America*, Acoustical Society of America, v. 97, n. 5, p. 3051–3063, 1995.
- LINS, O. G.; PICTON, T. W. Auditory steady-state responses to multiple simultaneous stimuli. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, Elsevier, v. 96, n. 5, p. 420–432, 1995.
- LINS, O. G. et al. Frequency-specific audiometry using steady-state responses. *Ear and hearing*, LWW, v. 17, n. 2, p. 81–96, 1996.
- MARIN, J.-M. et al. Approximate Bayesian computational methods. *Statistics and Computing*, Springer, v. 22, n. 6, p. 1167–1180, 2012.
- MAURIZI, M. et al. 40-Hz steady-state responses in newborns and in children. *Audiology*, Taylor & Francis, v. 29, n. 6, p. 322–328, 1990.
- MELGES, D. B.; INFANTOSI, A. F. C.; MIRANDA DE Sá, A. M. F. L. Using Objective Response Detection techniques for detecting the tibial somatosensory evoked response with different stimulation rates. *Journal of neuroscience methods*, Elsevier, v. 195, n. 2, p. 255–260, 2011.
- MIRANDA DE SÁ, A.; INFANTOSI, A. F. C. A coherence-based technique for evaluating the degree of synchronism in the EEG during sensory stimulation. *Rev Bras Eng Biomed*, v. 18, p. 39–49, 2002.
- MIRANDA DE SÁ, A. M. F. et al. Assessing time-and phase-locked changes in the eeg during sensory stimulation by means of spectral techniques. In: SPRINGER. *World Congress on Medical Physics and Biomedical Engineering, September 7-12, 2009, Munich, Germany*. [S.l.], 2009. p. 2136–2139.
- MIRANDA DE SÁ, A. M. F. M. A note on the sampling distribution of coherence estimate for the detection of periodic signals. *IEEE Signal Processing Letters*, IEEE, v. 11, n. 3, p. 323–325, 2004.



- MITRA, R.; MÜLLER, P. *Nonparametric Bayesian inference in biostatistics*. Switzerland: Springer, 2015.
- MUNNEKE, G. J. et al. A statistical comparison of EEG time- and time-frequency domain representations of error processing. *Brain Res.*, 2015.
- MØLLER, A. R. *Hearing: Anatomy, Physiology and Disorders of the Auditory System*. 2. ed. San Diego: Academic Press, 2006. 6–10 p.
- O'HAGAN, A. et al. *Uncertain judgements: eliciting experts' probabilities*. England: John Wiley & Sons, 2006.
- PANG, S. et al. The auditory P300 correlates with specific cognitive deficits in Parkinson's disease. *Journal of Neural Transmission-Parkinson's Disease and Dementia Section*, Springer, v. 2, n. 4, p. 249–264, 1990.
- PÉREZ-ABALO, M. C. et al. New system for neonatal hearing screening based on auditory steady state responses. *Journal of medical engineering & technology*, Taylor & Francis, v. 37, n. 6, p. 368–374, 2013.
- PHADIA, E. G. *Prior processes and their applications*. Berlin: Springer, 2015.
- PICTON, T. W. *Human auditory evoked potentials*. 1. ed. San Diego: Plural Publishing, 2010.
- PICTON, T. W. et al. Human auditory steady-state responses. *International journal of audiology*, Taylor & Francis, v. 42, n. 4, p. 177–219, 2003.
- PICTON, T. W.; VAN ROON, P.; JOHN, M. S. Human auditory steady-state responses during sweeps of intensity. *Ear and hearing*, LWW, v. 28, n. 4, p. 542–557, 2007.
- PURCELL, D. W.; JOHN, M. S. Evaluating the modulation transfer function of auditory steady state responses in the 65 Hz to 120 Hz range. *Ear and hearing*, LWW, v. 31, n. 5, p. 667–678, 2010.
- PURVES, D. et al. *Cognitive neuroscience*. 4. ed. [S.l.]: Sunderland: Sinauer Associates, Inc, 2008.
- REES, A.; GREEN, G.; KAY, R. Steady-state evoked responses to sinusoidally amplitude-modulated sounds recorded in man. *Hearing research*, Elsevier, v. 23, n. 2, p. 123–133, 1986.
- RESENDE, L. M. de et al. Auditory steady-state responses in school-aged children: a pilot study. *Journal of neuroengineering and rehabilitation*, BioMed Central, v. 12, n. 1, p. 13, 2015.
- REZENDE, C. F. de. *Limiaries auditivos eletrofisiológicos por resposta evocada auditiva em regime permanente em neonatos com audição normal*. 2015. Dissertação (Mestrado em Engenharia Elétrica) — PPGEE - Universidade Federal de Minas Gerais.
- RICKARDS, F. W. et al. Auditory steady-state evoked potential in newborns. *British Journal of Audiology*, v. 28, n. 6, p. 327–337, 1994.
- ROBERT, C. *The Bayesian choice: from decision-theoretic foundations to computational implementation*. New York: Springer Science & Business Media, 2007.

- RODRIGUEZ, R. et al. Human auditory steady state responses: effects of intensity and frequency. *Ear Hear*, v. 7, n. 5, p. 300–313, 1986.
- ROMÃO, M.; TIERRA-CRIOLLO, C. J. A bayesian approach to the spectral F-Test: Application to auditory steady-state responses. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 183, p. 105100, 2020.
- ROMÃO, M. W. *Sistema para detecção de limiar auditivo fisiológico com base no pontecial evocado em regime permanente*. 2009. Dissertação (Mestrado em Engenharia Elétrica) — PPGEE - Universidade Federal de Minas Gerais.
- ROSS, B. et al. A high-precision magnetoencephalographic study of human auditory steady-state responses to amplitude-modulated tones. *The Journal of the Acoustical Society of America*, Acoustical Society of America, v. 108, n. 2, p. 679–691, 2000.
- ROSS, B. et al. Frequency specificity of 40-Hz auditory steady-state responses. *Hearing research*, Elsevier, v. 186, n. 1-2, p. 57–68, 2003.
- ROSS, B. et al. The effect of attention on the auditory steady-state response. *Neurology & clinical neurophysiology: NCN*, v. 2004, p. 22–22, 2004.
- RUANAIDH, J. J. O.; FITZGERALD, W. J. *Numerical Bayesian methods applied to signal processing*. [S.l.]: Springer Science & Business Media, 2012.
- SANEI, S.; CHAMBERS, J. A. *EEG Signal Processing*. England: Wiley, 2007. v. 1. 289 p.
- SANTOS, T. et al. Detection efficiency of auditory steady state evoked by modulated noise. *Hearing Research*, v. 339, p. 125 – 131, 2016. ISSN 0378-5955.
- SCHMULIAN, D.; SWANEPOEL, D.; HUGO, R. Predicting pure-tone thresholds with dichotic multiple frequency auditory steady state responses. *Journal of the American Academy of Audiology*, American Academy of Audiology, v. 16, n. 1, p. 5–17, 2005.
- SCHOMER, D. L.; SILVA, F. H. L. *Niedermeyer's electroencephalography : basic principles, clinical applications, and related fields*. Philadelphia: Wolters Kluwer Health, 2010.
- SIMPSON, D. M. et al. Objective response detection in an electroencephalogram during somatosensory stimulation. *Annals of Biomedical Engineering*, Springer, v. 28, n. 6, p. 691–698, 2000.
- SININGER, Y. S. et al. Evaluation of speed and accuracy of next-generation auditory steady state response and auditory brainstem response audiometry in children with normal hearing and hearing loss. *Ear and hearing*, LWW, v. 39, n. 6, p. 1207–1223, 2018.
- SKOSNIK, P. D.; KRISHNAN, G. P.; O'DONNELL, B. F. The effect of selective attention on the gamma-band auditory steady-state response. *Neuroscience letters*, Elsevier, v. 420, n. 3, p. 223–228, 2007.
- SOUZA, D. P. M. de. *Limiar Auditivo com o Potencial Evocado em Regime Permanente Utilizando Técnicas de Detecção Objetiva*. 2011. Dissertação (Mestrado em Engenharia Elétrica) — PPGEE - Universidade Federal de Minas Gerais.

- STAPELLS, D. Threshold estimation by the tone-evoked auditory brainstem response: A literature meta-analysis. *Canadian Journal of Speech-Language Pathology and Audiology*, v. 24, p. 74–83, 01 2000.
- STÜRZEBECKER, E. et al. New efficient stimuli for evoking frequency-specific auditory steady-state responses. *Journal of the American Academy of Audiology*, American Academy of Audiology, v. 17, n. 6, p. 448–461, 2006.
- SYVERSVEEN, A. R. Noninformative bayesian priors. interpretation and problems with construction and applications. *Preprint statistics*, v. 3, n. 3, p. 1–11, 1998.
- TEBALDI, C. et al. Quantifying uncertainty in projections of regional climate change: A Bayesian approach to the analysis of multimodel ensembles. *Journal of Climate*, v. 18, n. 10, p. 1524–1540, 2005.
- TIERRA-CRIOLLO, C. J. *Monitorização Objetiva da Resposta à Estimulação Somato-sensitiva utilizando Parâmetros Espectrais*. 2001. Tese (Doutorado) — COPPE - Universidade Federal do Rio de Janeiro.
- TRUCCO, P. et al. A Bayesian Belief Network modelling of organisational factors in risk analysis: A case study in maritime transportation. *Reliability Engineering & System Safety*, Elsevier, v. 93, n. 6, p. 845–856, 2008.
- TSUCHIMOTO, R. et al. Reduced high and low frequency gamma synchronization in patients with chronic schizophrenia. *Schizophrenia research*, Elsevier, v. 133, n. 1-3, p. 99–105, 2011.
- TURNER, B. M.; ZANDT, T. V. A tutorial on approximate Bayesian computation. *Journal of Mathematical Psychology*, Elsevier, v. 56, n. 2, p. 69–85, 2012.
- VALDES, J. L. et al. Comparison of statistical indicators for the automatic detection of 80 Hz auditory steady state responses. *Ear and hearing*, LWW, v. 18, n. 5, p. 420–429, 1997.
- VAN DER REIJDEN, C. S.; MENS, L. H.; SNIK, A. F. Signal-to-noise ratios of the auditory steady-state response from fifty-five EEG derivations in adults. *Journal of the American Academy of Audiology*, American Academy of Audiology, v. 15, n. 10, p. 692–701, 2004.
- VAN DEURSEN, J. et al. 40-Hz steady state response in Alzheimer’s disease and mild cognitive impairment. *Neurobiology of aging*, Elsevier, v. 32, n. 1, p. 24–30, 2011.
- VAN DUN, B.; WOUTERS, J.; MOONEN, M. Independent component analysis applied on multi-channel auditory steady-state response measurements. In: *Proc. of the ICA Research Network International Workshop (ICArn)*. [S.l.: s.n.], 2006. p. 89–92.
- VAN DUN, B.; WOUTERS, J.; MOONEN, M. Multi-channel Wiener filtering based auditory steady-state response detection. In: IEEE. *2007 IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP’07*. [S.l.], 2007. v. 2, p. II–929.
- VAN MAANEN, A.; STAPELLS, D. R. Comparison of multiple auditory steady-state responses (80 versus 40 Hz) and slow cortical potentials for threshold estimation in hearing-impaired adults. *International Journal of Audiology*, Taylor & Francis, v. 44, n. 11, p. 613–624, 2005.

- VAUGHAN, H. G.; RITTER, W. The sources of auditory evoked responses recorded from the human scalp. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 28, n. 4, p. 360–367, 1970.
- VICTOR, J. D.; MAST, J. A new statistic for steady-state evoked potentials. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 78, n. 5, p. 378–388, 1991.
- VOICIKAS, A. et al. Effect of attention on 40 Hz auditory steady-state response depends on the stimulation type: Flutter amplitude modulated tones versus clicks. *Neuroscience letters*, Elsevier, v. 629, p. 215–220, 2016.
- WAKEFIELD, J. *Bayesian and frequentist regression methods*. New York: Springer Science & Business Media, 2013.
- YOKOTA, Y.; NARUSE, Y. Phase coherence of auditory steady-state response reflects the amount of cognitive workload in a modified N-back task. *Neuroscience research*, Elsevier, v. 100, p. 39–45, 2015.
- ZANOTELLI, T. *Técnicas multivariadas para detecção das respostas auditivas em regime permanente*. 2011. Dissertação (Mestrado em Engenharia Elétrica) — PPGEE - Universidade Federal de Minas Gerais.
- ZUREK, P. Detectability of transient and sinusoidal otoacoustic emissions. *Ear and hearing*, v. 13, n. 5, p. 307–310, 1992.

## APÊNDICE A - O SISTEMA AUDITIVO

O sistema auditivo é a modalidade sensorial especializada na captação, percepção e interpretação de sons. Sua estrutura complexa possibilita que as ondas de pressão e rarefação que se propagam, sobretudo pelo ar, sejam conduzidas até órgãos receptores para a transdução das vibrações mecânicas em sinais neurais que serão transmitidos até o córtex cerebral (KANDEL et al., 2014). Em virtude de sua complexidade e da especialização de suas estruturas, o sistema auditivo é dividido em duas partes: o sistema auditivo periférico e o sistema auditivo central. A seguir, serão apresentados com maiores detalhes os aspectos anatômicos e fisiológicos de cada uma dessas duas divisões.

### A.1 Sistema auditivo periférico

O sistema auditivo periférico é constituído pela orelha externa, orelha média e orelha interna e será melhor detalhado nos subitens a seguir.

#### A.1.1 Orelha externa

A orelha externa é composta pelo pavilhão auricular e pelo meato acústico externo que são responsáveis, respectivamente, pela captação e condução das ondas sonoras até a membrana timpânica. Além disso, ela realiza a proteção do sistema auditivo contra agentes nocivos e também promove a amplificação sonora (BEAR; CONNORS; PARADISO, 2017).

O pavilhão auricular (também chamado de pina) é a porção visível do sistema auditivo que fica localizado na parte lateral da cabeça. É composto por tecido cartilaginoso revestido por pele e por alguns músculos vestigiais que possibilitam a sua movimentação, ainda que de forma muito limitada se comparado a outros mamíferos que possuem a habilidade de direcioná-lo para a fonte sonora (BEAR; CONNORS; PARADISO, 2017). Seu posicionamento oblíquo em relação ao plano sagital e sua estrutura, composta por uma série de sulcos e reentrâncias, possibilita a captação do som e seu direcionamento para o meato acústico externo.

O meato acústico externo, por sua vez, é um canal em forma de “S”, revestido por pele, que apresenta, em média, 9 mm de altura, 6,5 mm de largura e 2,5 cm de profundidade. Seu terço inicial tem como revestimento externo o tecido cartilaginoso, enquanto os outros dois terços estão circundados por tecido ósseo (GELFAND, 2016). A pele da porção cartilaginosa é revestida por pelos e glândulas (sebáceas e serosas), que secretam uma substância gordurosa denominada cerúmen, cuja função é impermeabilizar o canal e protegê-lo de partículas e da ação de microrganismos (MØLLER, 2006).

O meato acústico externo não se restringe apenas à condução dos estímulos sonoros até a membrana timpânica e na proteção do sistema auditivo. Sua forma e suas dimensões fazem com que esta estrutura tenha o comportamento de um tubo ressonador, limitado na extremidade aberta pela entrada do meato acústico e na extremidade fechada pela membrana timpânica (HUMES; BESS, 2008).

Além do meato acústico, há também padrões de ressonância nas diversas cavidades existentes no pavilhão auricular, com destaque para a região denominada concha. Em um adulto, as frequências de ressonância do meato acústico e da concha são de, aproximadamente, 2,5 kHz e 5 kHz, respectivamente. Em ambas, o ganho de pressão obtido é em torno de 10 dB (HUMES; BESS, 2008).

### A.1.2 Orelha média

A orelha média é uma cavidade no osso temporal com volume aproximado de 2 cm<sup>3</sup>, preenchida com ar, na qual se encontram estruturas responsáveis por transmitir à orelha interna a onda sonora captada pela orelha externa. Seus elementos constituintes são a membrana timpânica; a cadeia ossicular; os músculos tensores do tímpano e estapédio; e a tuba auditiva (MØLLER, 2006).

A membrana timpânica possui um formato ovalado, com uma área de superfície de aproximadamente 85 mm<sup>2</sup> e apresenta uma leve concavidade quando vista do meato acústico externo. Sua composição é dada pela sobreposição de fibras de colágeno, o que resulta em uma estrutura leve e rígida, ideal para a conversão das ondas sonoras em vibrações (MØLLER, 2006).

Esta membrana é continuada pela cadeia ossicular formada pelo martelo, bigorna e estribo. Esses três ossículos, os menores do corpo humano, são responsáveis por transmitir, para a orelha interna, as vibrações da membrana timpânica induzidas pelas ondas sonoras (GELFAND, 2016). O martelo, primeiro ossículo da cadeia, com cerca de 9 mm de comprimento e 25 mg de peso, se liga à membrana timpânica por meio de um processo lateral chamado cabo (ou manúbrio) do martelo. Já a outra extremidade, a cabeça, conecta-se à bigorna por uma junção em forma de cela (GELFAND, 2016). A bigorna, que possui um comprimento médio de 7 mm e peso aproximado de 30 mg, dá continuidade à cadeia se ligando ao estribo por meio do processo lenticular. Por fim, o estribo, que é o menor (3,5 mm) e mais leve (3 mg) dentre os três ossos, completa a cadeia ossicular com a ligação de sua base à janela oval da cóclea (GELFAND, 2016).

Como a cadeia ossicular é uma estrutura móvel, sua fixação se dá por meio de tendões e ligamentos que se projetam da parede interna da cavidade timpânica. Além desses, compõem também a estrutura do ouvido médio, o músculo tensor do tímpano e o músculo estapédio. O músculo tensor do tímpano tem sua origem próximo à entrada da tuba auditiva e sua inserção se dá no cabo do martelo. Sua contração puxa esse osso para dentro da cavidade da orelha média, tensionando a membrana timpânica. Já o músculo estapédio tem origem na parede posterior da cavidade da orelha média e se insere no estribo. Sua contração afeta a mobilidade desse osso (BEAR; CONNORS; PARADISO, 2017). A ação desses dois músculos é involuntária e se manifesta em um processo denominado reflexo acústico, que visa a reduzir a quantidade de energia que é transmitida à orelha interna quando ocorrem estímulos sonoros intensos.

As estruturas da orelha média estão localizadas em uma cavidade repleta de ar que faz interface com o ambiente externo por meio da membrana timpânica. Quando há uma eventual diferença de pressão entre esses dois meios, ocorre uma deflexão dessa membrana, forçando-a em direção à região com menor pressão. O estiramento resultante dessa ação compromete sua capacidade vibratória e, conseqüentemente, afeta a transmissão do estímulo sonoro até a orelha interna (GELFAND, 2016). Assim, a condição ideal ocorre quando há uma equalização da pressão nos dois lados da membrana, ou seja, quando a pressão da cavidade da orelha média é igual à pressão do ambiente externo.

Essa situação é viabilizada por um canal denominado tuba auditiva, que se estende da parede anterior da orelha média até a região da nasofaringe. Este canal é constituído por uma porção óssea, localizada próxima à orelha média, e outra cartilaginosa, que forma o restante de sua extensão. A porção cartilaginosa atua como uma válvula e mantém o canal fechado. A sua abertura se dá por meio da contração do músculo tensor do véu palatino, localizado na faringe, que pode ser naturalmente contraído ao engolir ou bocejar (MØLLER, 2006).

É importante destacar que a ação da orelha média é fundamental na transmissão

das ondas sonoras da orelha externa até a orelha interna. As ondas sonoras que se propagam pelo ar ao longo da orelha externa precisam ser transmitidas para o interior da cóclea, que é uma região repleta por líquidos. Nela estão as estruturas responsáveis pela conversão da vibração sonora em sinais neurais.

A impedância do líquido no interior da cóclea é muito maior que a impedância do ar e, por isso, a transmissão da vibração da membrana timpânica diretamente para a janela oval da cóclea resultaria em uma perda de 99,9% da energia sonora por reflexão. Isso faria com que apenas 0,1% da energia fosse transmitida, o que limitaria a percepção dos estímulos sonoros vindos do ambiente externo (HUMES; BESS, 2008). As estruturas da orelha média se valem de dois mecanismos de amplificação para compensar essa perda em função da diferença de impedância. O primeiro é resultante da diferença de área entre a membrana timpânica e a janela oval da cóclea. O segundo está relacionado às características mecânicas da cadeia ossicular.

A área da membrana timpânica diretamente envolvida no acoplamento mecânico entre a orelha externa e a orelha interna é de aproximadamente 55 mm<sup>2</sup>. A janela oval da cóclea, por sua vez, possui uma área de apenas 3,2 mm<sup>2</sup>. Essa diferença entre as áreas das duas superfícies faz com que a força exercida na membrana timpânica (maior área) seja transmitida para a pequena área da janela oval, resultando em um aumento da pressão. O ganho de pressão resultante desse primeiro mecanismo é de, aproximadamente, 24 dB (HUMES; BESS, 2008).

A cadeia ossicular, por sua vez, forma uma alavanca de primeira classe, na qual o cabo do martelo constitui o braço maior; a junção entre martelo e bigorna forma o ponto de apoio; e o ramo longo da bigorna atua como o braço menor. Esta constituição mecânica faz com que a força aplicada pela membrana timpânica no cabo do martelo (braço maior) seja amplificada na outra extremidade da alavanca em função do menor comprimento do braço formado pelo ramo longo da bigorna, conforme descreve a equação fundamental das alavancas. Essa força amplificada age sobre a janela oval da cóclea, resultando em um ganho de pressão de aproximadamente 2 dB (GELFAND, 2016).

### A.1.3 Orelha interna

A orelha interna, também chamada de labirinto, está localizada na porção petrosa do osso temporal. Sua forma complexa pode ser melhor compreendida como uma estrutura óssea tubular (labirinto ósseo) que abriga um duto membranoso (labirinto membranoso) onde estão os órgãos sensoriais responsáveis pela audição e pelo equilíbrio (KANDEL et al., 2014).

O labirinto ósseo pode ser dividido em três partes: canais semicirculares, vestíbulo e cóclea. Os dois primeiros abrigam o órgão sensorial do sistema vestibular, responsável,



principalmente, pelo equilíbrio e pela manutenção da postura (HUMES; BESS, 2008). A cóclea, por sua vez, abriga o órgão responsável pela audição e, portanto, será descrita com maiores detalhes na seção a seguir:

#### *A.1.3.1 Cóclea*

A cóclea é uma estrutura óssea em forma espiral com aproximadamente 2,75 voltas, cujo comprimento nos seres humanos varia entre 3,1 mm e 3,3 mm. Em sua base encontram-se duas aberturas, denominadas janela oval (onde se apoia a base do estribo) e a janela redonda (encoberta por uma membrana) (MØLLER, 2006). Um corte transversal da cóclea revela que seu duto interno é particionado em três câmaras. São elas: escala média, escala vestibular e escala timpânica (MØLLER, 2006).

A escala média ocupa a posição central, estando separada da escala vestibular por meio da membrana de Reissner e da escala timpânica pela membrana basilar. Seu interior é preenchido pela endolinfa, um líquido rico em potássio e com baixa concentração de sódio. Além disso, nessa câmara, sobre a membrana basilar, encontra-se o órgão de Corti, que é a estrutura responsável pela geração dos sinais neurais em resposta aos estímulos sonoros (BEAR; CONNORS; PARADISO, 2017). As escalas vestibular e timpânica, por sua vez, são preenchidas pela perilinfa, um líquido cuja composição é semelhante ao fluido extracelular, rico em sódio e com baixa concentração de potássio. Nas bases das escalas vestibular e timpânica encontram-se, respectivamente, a janela oval e a janela redonda. Essas duas câmaras se comunicam por meio do helicotrema, um pequeno orifício localizado no ápice da cóclea (BEAR; CONNORS; PARADISO, 2017).

Na presença de um estímulo sonoro, a base do estribo se desloca como um pistão, causando uma variação de pressão na perilinfa que se propaga ao longo das escalas vestibular e timpânica até atingir a janela redonda. Assim, por exemplo, um movimento do estribo em direção ao interior da cóclea empurra a perilinfa, causando uma deflexão da janela redonda em direção à cavidade da orelha média.

É importante ressaltar que a membrana basilar não é completamente rígida. As variações de pressão causadas pela movimentação alternada do estribo resultam em uma oscilação desta membrana. A forma como essa oscilação se dá, entretanto, está diretamente ligada a duas de suas características estruturais. A primeira diz respeito à sua dimensão, sendo mais larga na região apical (0,42 mm - 0,65 mm) e progressivamente mais estreita à medida que se desloca em direção à base (0,08 mm - 0,16 mm). A segunda característica é a variação na sua rigidez, sendo mais flexível no ápice e mais rígida na base (PURVES et al., 2008).

Assim, as vibrações induzidas pelo movimento do estribo geram um padrão de oscilação na membrana basilar que se propaga ao longo de sua extensão, partindo da base

até o ápice. A amplitude dessa oscilação, entretanto, é máxima em uma região limitada que, em função de suas características mecânicas, responde melhor à frequência do estímulo. Esse comportamento faz com que a membrana basilar atue como um analisador de espectro cuja organização se dá de forma tonotópica, ou seja, a região basal responde a altas frequências enquanto a região apical responde a frequências mais baixas. Nos seres humanos, a faixa de resposta da membrana basilar está entre 20 Hz e 20 kHz, aproximadamente (KANDEL et al., 2014).

#### A.1.4 Órgão de Corti

O órgão de Corti está localizado na escala média, sobre toda a extensão da membrana basilar. Sua estrutura é formada por células epiteliais especializadas denominadas células ciliadas internas (CCI) e células ciliadas externas (CCE), que recebem esse nome por possuírem pequenos cílios em seu pólo apical (MØLLER, 2006).

As CCI são os receptores sensoriais da audição, responsáveis pela transdução da energia hidráulica resultante da vibração da orelha média em sinais elétricos. Na cóclea humana existem aproximadamente 3.500 dessas células distribuídas em linha na porção mais interna do órgão de Corti. Sua estrutura interna é composta por mitocôndrias, complexos de Golgi e outras organelas associadas à intensa atividade metabólica inerente ao processo sensorial (GELFAND, 2016).

As CCE são mais numerosas, contando com aproximadamente 12.000 células em formato cilíndrico, organizadas em três linhas na porção externa do órgão de Corti. Em seu interior encontram-se proteínas contráteis e outras estruturas associadas a células musculares que lhe conferem capacidade de contração em resposta a estímulos neurais. Acredita-se que essa capacidade contrátil tem a função de amplificar o movimento da membrana basilar na presença de estímulos sonoros de baixa intensidade, o que auxilia as CCI no processo de transdução (GELFAND, 2016).

Quando a membrana basilar vibra, toda a estrutura que suporta as células ciliadas também se desloca, causando o cisalhamento dos cílios contra a membrana tectória. O deslocamento desses cílios em uma direção causa a despolarização das células enquanto a deflexão na outra direção resulta na hiperpolarização (BEAR; CONNORS; PARADISO, 2017). Deflexões de aproximadamente 0,3 nm já são suficientes para que um som seja percebido, gerando um potencial receptor próximo à 100  $\mu\text{V}$ , mostrando o quão sensível são essas estruturas.

Assim, as células ciliadas apresentam um padrão de despolarização / hiperpolarização que tende a acompanhar a frequência de oscilação da membrana basilar e é manifestado no potencial receptor resultante. Os potenciais receptores gerados são integrados e, caso excedam um valor limiar, desencadeiam a geração de um potencial de ação nos neurônios

do gânglio espiral.

## A.2 Sistema auditivo central

O sistema auditivo central compreende as vias ascendentes e descendentes, que são responsáveis pela transmissão de sinais neurais entre o sistema auditivo periférico e o córtex cerebral. O início do trajeto ascendente se dá no nervo auditivo, que é um dos ramos do nervo vestibulo coclear, composto por cerca de 30.000 neurônios bipolares de primeira ordem e cujos corpos celulares estão localizados no gânglio espiral. As fibras que constituem esse nervo são classificadas como tipo I e tipo II. As fibras do tipo I são mielinizadas. Nelas, a porção periférica faz sinapse com as CCI e a porção central com o núcleo coclear ventral. As fibras do tipo II são desmielinizadas e constituem apenas 1% do total de fibras do nervo auditivo. São responsáveis pela transmissão dos potenciais gerados pelas CCE até núcleo coclear dorsal (MØLLER, 2006).

A trajetória ascendente segue ipsilateralmente para o núcleo coclear, o primeiro núcleo relé da via auditiva, localizado na junção bulbo-pontina, onde ocorrem as sinapses com os neurônios de segunda ordem (GELFAND, 2016). A partir do núcleo coclear, a via auditiva se ramifica em diversas vias paralelas. Alguns neurônios seguem ipsilateralmente para o complexo olivar superior, porém a maior parte cruza para o lado oposto do tronco encefálico e segue para o complexo olivar contralateral ou ascende pelo lemnisco lateral até o colículo inferior (KANDEL et al., 2014).

O complexo olivar superior abriga os neurônios de terceira ordem e constitui o primeiro grupo de núcleos que integram informações vindas das duas orelhas. Essa estrutura está envolvida na percepção da direção sonora por meio da comparação dos tempos de chegada dos estímulos e suas diferentes intensidades (BEAR; CONNORS; PARADISO, 2017). O colículo inferior é um núcleo relé localizado no mesencéfalo que recebe projeções de quase todos os outros núcleos. Suas eferências projetam-se até o núcleo geniculado medial no tálamo, que consiste na última estrutura subcortical da via auditiva ascendente (MØLLER, 2006).

Os neurônios que deixam o núcleo geniculado medial seguem, então, para o córtex auditivo primário, localizado no giro transversal de Heschl, na porção superior do lobo temporal. A partir daí, ocorrem projeções para outras regiões do córtex auditivo, bem como para áreas de associação. Há ainda projeções que se comunicam com o córtex auditivo do lado oposto (GELFAND, 2016).

A via auditiva é um sistema de organização tonotópica, uma vez que os neurônios estão anatomicamente arranjados de acordo com a frequência com as quais estão associados. Assim, as baixas frequências estão na porção anterior enquanto as altas frequências se encontram na região posterior (BEAR; CONNORS; PARADISO, 2017).

## APÊNDICE B - LIMIARES DETECTOR BAYESIANO PARA SFT

As Figuras 35 a 41 apresentam os valores críticos do detector bayesiano ( $\phi_{crit\ Bayes}$ ) para SFT, considerando todos os valores de  $M$  analisados. As curvas de contorno representam a variação dos valores críticos para diferentes escolhas de  $P(H0)$ , em função da RSR. Nas figuras constam ainda o valor esperado de SFT (curvas pretas sólidas) com os respectivos intervalos de confiança de 95% (curvas pretas tracejadas). Considerando, por exemplo, os achados apresentados na Figura 35, é possível observar que a escolha de  $P(H0) = 0,505$  resulta em um limiar de decisão que cresce assintoticamente para infinito à medida que o valor da RSR é reduzido em direção a  $RSR = -25$  dB (vide a curva de contorno “0.505” indicada na Figura 35). Pode-se verificar que no intervalo aproximado  $-23$  dB  $< RSR < -10$  dB o valor crítico apresenta uma queda acentuada, sendo ultrapassado pelo valor esperado de SFT em  $RSR \approx -13$  dB, o que sugere a detecção de resposta a partir deste ponto. Embora apresente um crescimento a partir de  $RSR \approx -5$  dB, a curva do valor crítico referente a  $P(H0) = 0,505$  permanece abaixo do valor esperado de SFT, chegando a ser ultrapassada também pelo limite inferior do intervalo de confiança a partir de  $RSR \approx 12$  dB, o que dá ainda mais suporte para a decisão pela presença de resposta.




Figura 35 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=4$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 36 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=12$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 37 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=16$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.

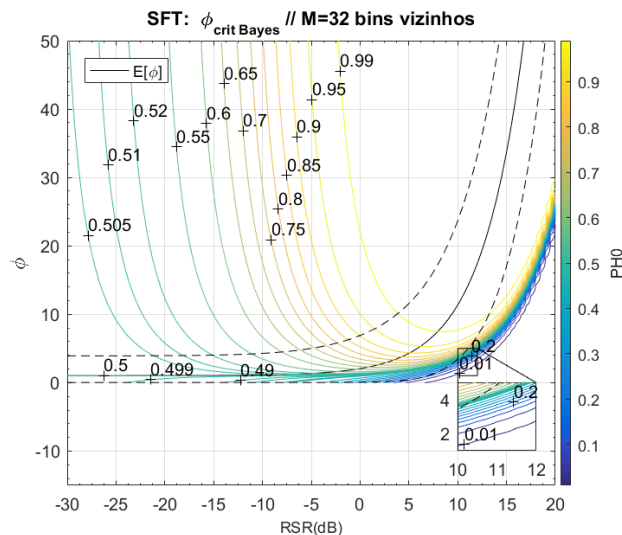


Figura 38 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=32$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 39 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=48$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 40 – Valores críticos do detector bayesiano( $\phi_{crit Bayes}$ ) para SFT ( $M=64$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 41 – Valores críticos do detector bayesiano ( $\phi_{crit Bayes}$ ) para SFT ( $M=96$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste SFT e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.



## APÊNDICE C - LIMIARES DETECTOR BAYESIANO PARA MSC




Figura 42 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=4$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 43 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=12$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 44 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=16$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H_0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 45 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=32$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.

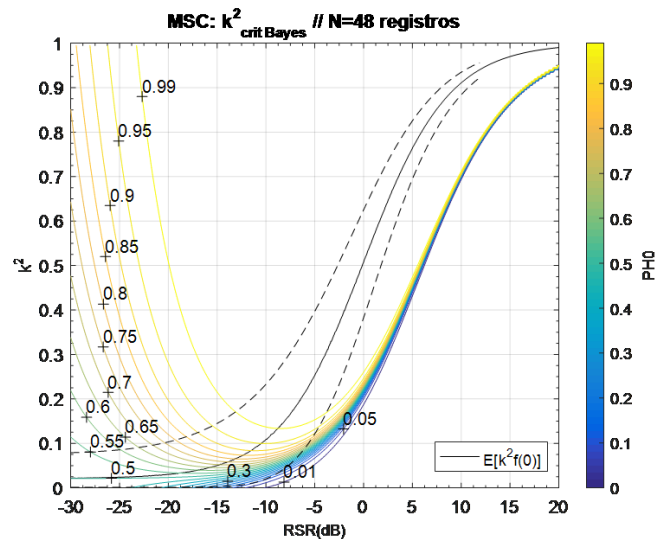


Figura 46 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=48$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.

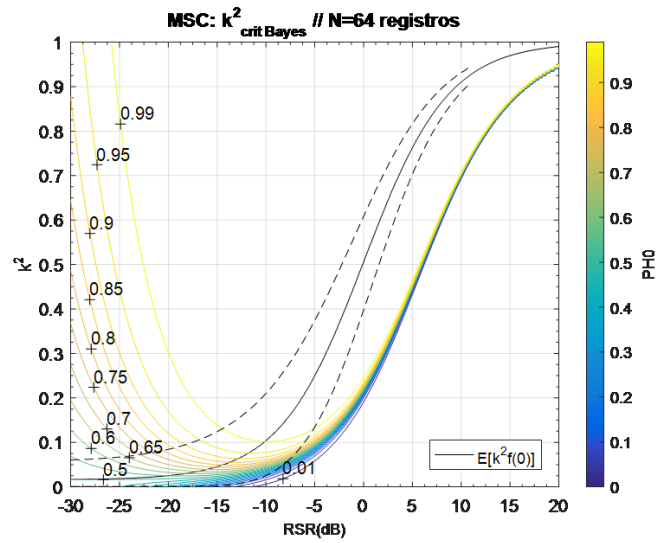


Figura 47 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=64$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.




Figura 48 – Valores críticos do detector bayesiano ( $k^2_{crit Bayes}$ ) para MSC ( $N=96$ ): As curvas de contorno representam os valores críticos associados aos diversos valores que podem ser atribuídos à  $P(H0)$  em função da RSR. A linha preta sólida indica o valor esperado para o teste MSC e as linhas pretas tracejadas indicam o intervalo de confiança de 95%.

Fonte: Dados da pesquisa.