



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

Tese de Doutorado

**Separação e Identificação de Múltiplas Fontes
Eletromagnéticas Usando o Método de Análise
em Componentes Independentes e o
Coeficiente de Correlação**

Paulo Ixtânio Leite Ferreira

Orientadores:

Prof. Dr. Glauco Fontgalland

Prof. Dr. Bruno Barbosa Albert

Campina Grande – PB, maio de 2014.

Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

**Separação e Identificação de Múltiplas Fontes
Eletromagnéticas Usando o Método de Análise em
Componentes Independentes e o Coeficiente de
Correlação**

Paulo Ixtânio Leite Ferreira

*Tese de Doutorado submetida ao Programa de Pós-Graduação em Engenharia Elétrica
da Universidade Federal de Campina Grande como parte dos requisitos para obtenção do
título de Doutor em Engenharia Elétrica.*

Área de Conhecimento: Micro-ondas e Eletromagnetismo Aplicados

Orientadores:

Prof. Dr. Glauco Fontgalland

Prof. Dr. Bruno Barbosa Albert

Campina Grande – PB
© Paulo Ixtânio Leite Ferreira



F383s

Ferreira, Paulo Ixtânio Leite.

Separação e identificação de múltiplas fontes eletromagnéticas usando o método de análise em componentes independentes e o coeficiente de correlação / Paulo Ixtânio Leite Ferreira. - Campina Grande, 2014.

168 f.

Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2014.

"Orientação: Prof. Dr. Glauco Fontgalland, Prof. Dr. Bruno Barbosa Albert".

Referências.

1. Separação Cega de Fontes. 2. ICA. 3. FastICA. 4. Múltiplas Fontes Eletromagnéticas Irradiantes. 5. Tese - Engenharia Elétrica. I. Fontgalland, Glauco. II. Albert, Bruno Barbosa. III. Universidade Federal de Campina Grande - Campina Grande (PB) IV. Título

CDU 621.3(043)

**"SEPARAÇÃO E IDENTIFICAÇÃO DE MÚLTIPLAS FONTES ELETROMAGNÉTICAS
USANDO O MÉTODO DE ANÁLISE EM COMPONENTES INDEPENDENTES E O
COEFICIENTE DE CORRELAÇÃO"**

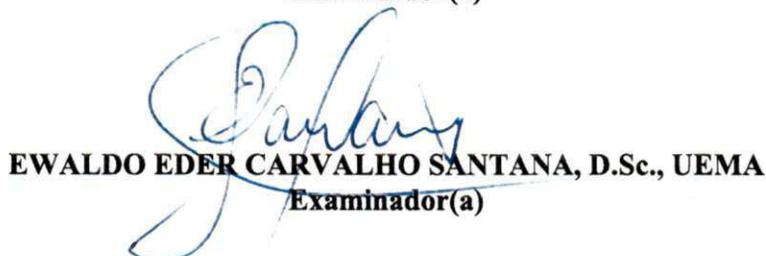
PAULO IXTÂNIO LEITE FERREIRA

TESE APROVADA EM 06/06/2014


GLAUCO FONTGALLAND, Dr., UFCG
Orientador(a)


BRUNO BARBOSA ALBERT, D.Sc., UFCG
Orientador(a)

ADAILDO GOMES D'ASSUNÇÃO, Dr., UFRN
Examinador(a)


EWALDO EDER CARVALHO SANTANA, D.Sc., UEMA
Examinador(a)


RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr., UFCG
Examinador(a)


JOSÉ EWERTON POMBO DE FARIAS, Dr., UFCG
Examinador(a)

CAMPINA GRANDE - PB

RESUMO

Atualmente o uso de equipamentos que usam tecnologia sem fio tem aumentado significativamente a quantidade de fontes eletromagnéticas (EM) e, conseqüentemente, a preocupação em identificar e separar múltiplas fontes fisicamente muito próximas. Essa situação é o alvo de estudo nesta pesquisa. Descreve-se o caso de como duas fontes EM irradiantes podem ser separadas apresentando uma pequena diferença em frequência (ΔF), mesma amplitude e fase. Isso é conseguido sem conhecimento prévio das fontes ou do ambiente onde elas estão inseridas. Neste trabalho são apresentados resultados de medições, para fontes separadas por distâncias de até $d = \lambda_0/10$. Em seguida, são mostradas a separação e identificação de múltiplas fontes com $\Delta F = 0,63\%$, geradas por equipamentos diferentes. Um estudo de sensoriamento espectral de canais de TV (digital e analógica) foi desenvolvido visando à aplicação em rádio cognitivo. Para estes casos, o método de análise em componente independente (ICA) é aplicado e o algoritmo FastICA é usado na sua implementação. É mostrada a limitação no uso dos procedimentos tradicionais para fontes semelhantes e espacialmente muito próximas. Um novo procedimento de coleta dos dados foi proposto baseado na reconstrução matemática dos sinais a partir da medição da fase e amplitude. São apresentados resultados para a influência do número, do posicionamento e da disposição dos sensores na resposta do ICA. O coeficiente de correlação é utilizado para quantificar quanto o sinal estimado é linearmente similar ao sinal original. Em alguns casos esses valores chegam a 0,99. Os resultados obtidos são considerados promissores, quando se leva em conta a complexidade do ambiente, a pequena diferença em frequência, o número e a proximidade das fontes.

Palavras-chaves: Separação cega de fontes, ICA, FastICA, Múltiplas fontes eletromagnéticas irradiantes, Coeficiente de correlação, Rádio cognitivo.

ABSTRACT

Currently the use of wireless has significantly increased the amount of electromagnetic sources (EM) and hence the concern on identification and separation of multiple sources physically closed. This situation is the main focus of this research, where is described the case of separation of two EM radiating sources showing small difference in frequency (ΔF), same amplitude and phase. This is accomplished without prior knowledge of the sources or the environment in which they are inserted. Experimental results, in which the sources are separated by distance of $d = \lambda_0/10$ is presented. Then, there are shown the separation and identification of multiple sources with $\Delta F = 0.63\%$, generated by different equipment. A study of TV channels (digital and analog) spectrum sensing is developed to cognitive radio. For all cases presented above the method of the independent component analysis (ICA) was applied and the FastICA algorithm used for its implementation. The limitations of the traditional procedures for similar sources and spatially very close are shown. A new procedure of data collection is proposed based on the mathematical reconstruction of signals by measuring its phase and amplitude. Results for the influence of the number, positioning and arrangement of sensors, in the ICA response are presented. The correlation coefficient is used to quantify the ICA response, by comparing how much the estimated signal is linearly similar to the original one. These values can reach up to 0.99. The results are considered promising, when taking into account the complexity of the measurement, the small frequency difference, and the number and proximity of the sources.

Keywords: Blind source separation, ICA, FastICA, Multiple radiating electromagnetic sources, Correlation coefficient, Cognitive radio.

SUMÁRIO

1.	Introdução	17
1.1	Contribuições do Trabalho.....	20
1.2	Objetivos.....	21
1.3	Organização da Tese	22
2.	Revisão Bibliográfica.....	24
2.1	Breve Histórico sobre o ICA.....	24
2.2	Aplicações	26
2.3	Restrições para Aplicação do ICA.....	31
2.4	Conclusão do Capítulo.....	38
3.	O Método de Análise da Componente Independente – ICA.....	40
3.1	Definição	40
3.2	Descrição Matemática do ICA.....	40
3.3	Funções Objetivo (ou Funções Custo)	44
3.4	Conclusão do Capítulo.....	48
4.	Simulações Usando o ICA	50
4.1	Programação do Algoritmo FastICA	50
4.2	Avaliação do FastICA.....	54
4.3	Avaliação das Funções Custo.....	56
4.4	Avaliação do ICA para Sinais Senoidais com Fases Determinadas	60
4.5	Conclusão do Capítulo.....	66
5.	Aplicação do ICA para Separação de Duas Fontes Irradiantes	67
5.1	Experimento 1: Duas Antenas Alimentadas com o mesmo Sinal e Dispostas Uma Atrás da Outra.....	68
5.1.1	Procedimentos de Medição.....	68
5.1.2	Proposta de Modificação nos Procedimentos de Medição.....	70
5.2	Experimento 2: Duas Antenas Alimentadas com Sinais Diferentes e Dispostas Uma Atrás da Outra.....	72
5.3	Experimento 3: Duas Antenas Excitadas com Sinais Iguais, Dispostas Lado a Lado.....	74
5.3.1	Experimento 3.1: Duas Fontes Idênticas, Dispostas uma Atrás da Outra e Distantes $\lambda_0/10$	78
5.4	Experimento 4: Variação da Distância entre Duas Antenas Iguais, Dispostas Uma Atrás da Outra.....	80
5.4.1.	Resultados para $D_1 = \lambda_0/4$	81
5.4.2.	Resultados para $D_2 = 3\lambda_0/8$	81
5.4.3.	Resultados para $D_3 = \lambda_0/2$	82
5.4.4.	Resultados para $D_4 = 3\lambda_0/4$	83

5.5	Experimento 5: Uma Antena Ativa, com Refletor Passivo.....	84
5.6	Experimento 6: Duas Fontes com Frequências Próximas	87
5.6.1	Procedimentos de Medição.....	87
5.7	Experimento 7: Duas Fontes com uma das Antenas Inclinada em 45°	92
5.8	Conclusão do Capítulo	95
6.	Aplicação do ICA para Separação de Múltiplas Fontes Irradiantes.....	98
6.1	Fontes Produzidas por Geradores de Micro-Ondas	99
6.1.1.	Fontes com Frequências muito Distintas	99
6.1.2.	Fontes com Frequências muito Próximas	103
6.1.3.	Fontes com Frequências Próximas.....	108
6.1.3.1.	Separação de Fontes com Baixa Relação Sinal-Ruído (SNR)	111
6.2	Fontes Produzidas por Rádio Definido por <i>Software</i> (RDS).....	115
6.2.1.	Fontes com Harmônicas	116
6.2.2.	Fontes com Frequências Próximas.....	120
6.3	Aplicação do ICA para Sensoriamento Espectral	123
6.3.1	Canais de TV (Analogica e Digital) Abertos	125
6.4	Separação de Sinais Modulados em Frequência.....	135
6.4.1	Simulação de Três Sinais FM com Frequências Diferentes	135
6.4.2	Experimentos com Dois Sinais FM com Portadoras Próximas	137
6.5	Conclusões do Capítulo	139
7.	Conclusões	142
7.1.	Perspectivas de Continuidade do Trabalho	147
	Referências Bibliográficas.....	149
	Anexo A	161
	AA – Algoritmo FastICA Desenvolvido no <i>Matlab</i> [®]	161
	AB – Ferramenta ICA Desenvolvida por Hyvärinen e Oja.....	165
	AC – Coeficiente de Reflexão das Antenas Log-Periódicas Planares.....	165

LISTA DE FIGURAS

Figura 1 - Distribuição conjunta de duas variáveis gaussianas independentes [43].	33
Figura 2 - Exemplo de mistura de duas fontes independentes, uma com distribuição uniforme (s_1), e outra com distribuição laplaciana (s_2). Nota-se, intuitivamente, que as observações (x_1 e x_2) possuem um perfil (contorno dos histogramas) mais próximas ao de uma variável aleatória gaussiana do que as variáveis originais [54].	35
Figura 3 - a) Histograma de uma variável super-gaussiana; b) Histograma de uma variável sub-gaussiana [43].	36
Figura 4 - Diagrama esquemático de mistura e separação do modelo do ICA, modificado de [58].	43
Figura 5 - Gráfico das funções G .	46
Figura 6 - Gráfico das funções g .	47
Figura 7 - a) e b) Sinais fontes: seno e cosseno; c) e d) Sinais misturados; e) e f) Sinais estimados após aplicar o ICA.	55
Figura 8 - a) e b) Sinais fontes aleatórios (amplitude entre -1 e 1); c) e d) Sinais misturados; e) e f) Sinais estimados após aplicar o ICA.	56
Figura 9 - Sinais fontes: seno, dente de serra, tangente e ruído impulsivo, respectivamente.	56
Figura 10 - Sinais originais: seno e ruído impulsivo, sinais misturados e estimados pelo ICA, respectivamente.	57
Figura 11 - Sinais originais: dente de serra e ruído impulsivo, sinais misturados e estimados pelo ICA, respectivamente.	59
Figura 12 - Sinais senoidais de fases diferentes.	61
Figura 13 - Sinais estimados pelo ICA: $sen(\omega t)$ e $sen(\omega t + 45)$.	61
Figura 14 - Sinais estimados pelo ICA: $sen(\omega t)$ e $sen(\omega t + 90)$.	62
Figura 15 - Sinal estimado pelo ICA: $sen(\omega t)$ ou $sen(\omega t + 180)$.	62
Figura 16 - Sinais estimados pelo ICA: a) $sen(\omega t)$ e $sen(\omega t + 179)$; b) $sen(\omega t)$ e $sen(\omega t + 1)$.	64
Figura 17 - Sinais AM, FM e seus respectivos espectros de frequência.	65
Figura 18 - Espectros estimados dos sinais AM e FM, respectivamente.	65
Figura 19 - Esquema de medições para o experimento 1.	69
Figura 20 - (a) Espectro emitido pelas duas antenas, ao mesmo tempo, medido nas posições 1 e 2; (b) Sinais estimados (recuperados) pelo ICA, a partir dos dados da Figura 20.a.	70

Figura 21 – (a) Sinais transmitidos e reconstruídos matematicamente para as antenas S_I e S_{II} ; (b) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2.....	71
Figura 22 – Sinais recuperados (estimados) pelo ICA, a partir dos dados da Figura 21.b.	72
Figura 23 – Espectro transmitido por S_I e por S_{II} , individualmente; (b) Espectro emitido pelas antenas Tx e medido nas posições P1 e P2.	73
Figura 24 – Sinais estimados pelo ICA, a partir dos dados da Figura 23.b.	73
Figura 25 – Esquema de medição para o experimento 3.	75
Figura 26 – (a) Sinais reconstruídos a partir dos dados medidos nas posições P1 e P2, com S_I e S_{II} excitadas ao mesmo tempo; (b) Sinais estimados pelo ICA, a partir dos dados da Figura 26.b.	76
Figura 27 – (a) Sinais emitidos pelas fontes S_I e S_{II} , individualmente; (b) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2, S_I e S_{II} excitadas ao mesmo tempo.....	77
Figura 28 – Sinais estimados pelo ICA, a partir dos dados da Figura 27.b.	77
Figura 29 – Esquema de medição para o experimento 4.	78
Figura 30 – (a) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2' (90° do eixo x); (b) Sinais estimados a partir dos dados da Figura 30.a.....	79
Figura 31 – Sinais fontes, reconstruídos matematicamente a partir dos dados medidos na posição P1.	80
Figura 32 – (a) Sinais reconstruídos matematicamente para as fontes distantes $\lambda_0/4$; (b) Sinais estimados a partir dos dados da Figura 32.a.	81
Figura 33 – (a) Sinais reconstruídos matematicamente para as fontes distantes $3\lambda_0/8$; (b) Sinais estimados a partir dos dados da Figura 33.a.	82
Figura 34 – (a) Sinais reconstruídos matematicamente para as fontes distantes $\lambda_0/2$; (b) Sinais estimados a partir dos dados da Figura 34.a.	83
Figura 35 – (a) Sinais reconstruídos matematicamente para as fontes distantes $3\lambda_0/4$; (b) Sinais estimados a partir dos dados da Figura 35.a.	83
Figura 36 – Esquema de medição para uma fonte ativa e um refletor.	85
Figura 37 – (a) Sinais medidos nas posições P1 e P2, para antena ativa mais antena dipolo como refletor; (b) Sinais estimados a partir dos dados da Figura 37.a. ..	85
Figura 38 – (a) Sinais medidos nas posições P1 e P2, para antena ativa + refletor retangular; (b) Sinais estimados a partir dos dados da Figura 38.a.	86
Figura 39 – Esquema ilustrativo para as medições dos experimentos 6 e 7.	88
Figura 40 – Sinais fontes, medidos na posição P0.	89
Figura 41 – (a) Sinais misturados medidos nas posições P0 a P4; (b) Sinais estimados a partir dos dados de três medições da Figura 41.a, P0 – P2.	89

Figura 42 – Sinais estimados a partir de quatro medições, P0 – P3.	90
Figura 43 – Sinais estimados a partir de cinco medições, P0 – P4.	91
Figura 44 – (a) Disposição das antenas transmissoras, S ₁ a 90° e S ₂ a 45°, em relação ao eixo x; (b) Sinais fontes medidos na posição P0.	93
Figura 45 – Sinais medidos em cinco posições diferentes, com as duas antenas excitadas.	93
Figura 46 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 45.a, P0 – P2; (b) Sinais estimados a partir dos dados de 4 medições da Figura 45.a, P0 – P3; (c) Sinais estimados a partir dos dados de 5 medições da Figura 45.a, P0 – P4.	94
Figura 47 – Esquema de medição para os ensaios com múltiplas fontes.	100
Figura 48 – Fontes originais, ruído ambiente, 1,20, 1,40 e 1,60 GHz, respectivamente.	101
Figura 49 – Sinais misturados, medidos em cinco posições diferentes.	101
Figura 50 – (a) Sinais estimados, usando 4 medições dos dados da Figura 49; (b) Sinais estimados, usando 5 medições dos dados da Figura 49.	102
Figura 51 – Exemplo ilustrativo do processo de determinação do limite de frequência entre dois sinais que o ICA pode separar e identificar.	104
Figura 52 – (a) Sinais fontes com $\Delta F = 0,07\%$; (b) Destaque entre as raias dos sinais fontes.	106
Figura 53 – Sinais medidos em 6 posições diferentes com todas as antenas excitadas.	106
Figura 54 – (a) Sinais estimados a partir dos dados de 4 medições da Figura 53, P0 – P3; (b) Sinais estimados a partir dos dados de 5 medições da Figura 53, P0 – P4; (c) Sinais estimados a partir dos dados de 6 medições da Figura 53, P0 – P5.	107
Figura 55 – (a) 3 Sinais fontes com $\Delta F = 0,63\%$ e amplitudes próximas; (b) Sinais medidos em 5 posições, com todas as fontes excitadas.	109
Figura 56 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 55.b, P0 – P2; (b) Sinais estimados a partir dos dados de 4 medições da Figura 55.b, P0 – P3; (c) Sinais estimados a partir dos dados de 5 medições da Figura 55.b, P0 – P4.	110
Figura 57 – (a) Sinais fontes, $\Delta F = 0,63\%$ e SNR ≈ 10 dB; (b) Sinais fontes, $\Delta F = 0,63\%$ e SNR ≈ 5 dB.	112
Figura 58 – (a) Sinais misturados, caso SNR ≈ 10 dB; (b) Sinais misturados, caso SNR ≈ 5 dB.	113
Figura 59 – (a) Sinais estimados a partir de 3 medições obtidas na Figura 58.a (caso SNR ≈ 10 dB); (b) Sinais estimados a partir de 3 medições obtidas na Figura 58.b (caso SNR ≈ 5 dB).	114

Figura 60 – (a) Sinais estimados a partir de 4 medições obtidas na Figura 59.a (caso SNR \approx 10 dB); (b) Sinais estimados a partir de 4 medições obtidas na Figura 59.b (caso SNR \approx 5 dB).....	114
Figura 61 – Esquema de medição para os ensaios usando RDS.	117
Figura 62 – (a) Sinais fontes produzidos via RDS com $\Delta F = 13,88\%$; (b) Sinais misturados e capturados em cinco posições diferentes.....	118
Figura 63 – (a) Sinais estimados a partir de 4 medições da Figura 62.b, $\Delta F = 13,88\%$; (b) Sinais estimados a partir de 5 medições da Figura 62.b, $\Delta F = 13,88\%$	119
Figura 64 – (a) Sinais fontes produzidos via RDS com $\Delta F = 0,63\%$; (b) Sinais misturados e capturados em cinco posições diferentes.....	121
Figura 65 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 64.b, P1 – P3; (b) Sinais estimados a partir dos dados de 4 medições da Figura 64.b, P1 – P4; (c) Sinais estimados a partir dos dados de 5 medições da Figura 64.b, P1 – P5.	122
Figura 66 – Diagrama de blocos de um rádio cognitivo baseado em OFDM, modificado de [77].	125
Figura 67 – Esquema de medição para sensoriamento do espectro de TV aberta..	126
Figura 68 – Espectro original dos usuários primários, medidos na posição P1.	127
Figura 69 – Composição do espectro recebido nas posições P1 –P4.....	128
Figura 70 – Espectro estimado usando o método ICA, considerando somente 3 medições daquelas mostradas na Figura 69.	131
Figura 71 – Espectro estimado pelo ICA, destacando as faixas vazias.	131
Figura 72 – Espectro estimado pelo ICA, a partir dos dados da Figura 69, nas posições P1 e P4. (a) espectros separados; (b) espectros juntos.	133
Figura 73 – Espectro dos sinais FM originais, simulados.	136
Figura 74 – (a) Sinais misturados aleatoriamente; (b) Sinais FM estimados pelo ICA a partir da mistura dos sinais originais (dados da Figura 74.a).....	136
Figura 75 – (a) Sinais FM originais; (b) Sinais FM misturados, medidos em 4 posições aleatórias diferentes.	138
Figura 76 – (a) Sinais FM estimados a partir de 3 medições (P0-P2); (b) Sinais FM estimados a partir de 4 medições (P0-P3).....	139
Figura AB 1 – Ferramenta para aplicar o algoritmo FastICA.....	165
Figura AC 1 – Coeficiente de reflexão da antena 1: WA5VJB_1, 0,9 – 2,6 GHz.....	166
Figura AC 2 – Coeficiente de reflexão da antena 2: WA5VJB_2, 0,9 – 2,6 GHz.....	167
Figura AC 3 – Coeficiente de reflexão da antena 1: WA5VJB_1, 0,85 – 6,5 GHz.....	167
Figura AC 4 – Coeficiente de reflexão da antena 2: WA5VJB_2, 0,85 – 6,5 GHz.....	168

LISTA DE TABELAS

Tabela 1 - Histogramas das fdp's conhecidas.	49
Tabela 2 - Avaliação das funções custo para os sinais fontes seno e ruído impulsivo.	58
Tabela 3 - Avaliação das funções custo para os sinais fontes dente de serra e ruído impulsivo.	59
Tabela 4 - Valores usados para determinar o limite numérico da diferença em frequência entre os sinais que o ICA consegue separar.	104
Tabela 5 - Erro obtido para o caso em que se utilizou 4 medições (Figura 54.a).....	107
Tabela 6 - Erro obtido para o caso em que se utilizou 5 medições (Figura 54.b)	107
Tabela 7 - Erro obtido para o caso em que se utilizou 6 medições (Figura 54.c).....	107
Tabela 8 - Valores da SNR para os sinais transmitidos por cada fonte. Caso de interesse SNR \approx 10 dB.	112
Tabela 9 - Valores da SNR para os sinais transmitidos por cada fonte. Caso de interesse SNR \approx 5 dB.	112
Tabela 10 - Parâmetros dos usuários primários (Canais de TV aberta)	128
Tabela 11 - Valores de energia para o espectro mostrado na Figura 69.....	130
Tabela 12 - Faixas recuperadas pelo método ICA, usando 3 pontos de medição.	132
Tabela 13 - Configuração dos geradores para produzir sinais FM.	137

LISTA DE SÍMBOLOS

A	Matriz de misturas
a_{ij}	Elementos da matriz de misturas
<i>Coefcorr</i>	Coefficiente de correlação
d	Distância entre as fontes
ΔF	diferença em frequência
$E\{\cdot\}$	Valor esperado
$f(\cdot)$	Função densidade de probabilidade
$f_{x,y}(x,y)$	Função densidade de probabilidade conjunta
$\ \cdot\ ^2$	Norma quadrada
$F_i(\cdot)$	Funções não polinomiais
f_i	Frequência da portadora
f_{modi}	Frequência de modulação
$G_i(\cdot)$	Funções custo
$g_i(\cdot)$	Primeira derivada das funções custo
$g'_i(\cdot)$	Segunda derivada das funções custo
$H(\cdot)$	Entropia
$h(\cdot)$	Entropia normalizada
I	Matriz identidade
$J(\cdot)$	Entropia diferencial normalizada (negentropia)
$K(\cdot)$	Curtose
$k_n(\cdot)$	Curtose normalizada
P_i	Posição da antena receptora
Rx	Antena receptora
s	Vetor de fontes originais
S_i	Fontes transmissoras
S_{21}	Coefficiente de transmissão das antenas
Tx	Antena transmissora
W	Matriz de separação
w_{ij}	Elementos da matriz de separação
x	Vetor de sinais observados
y	Vetor de componentes independentes

LISTA DE SÍMBOLOS

\bar{y}	Valor médio da variável
\mathbf{z}	Vetor branqueado
λ_0	Comprimento de onda, no espaço livre, das fontes EM
ν	Variável aleatória Gaussiana
ω	Frequência angular

LISTA DE ABREVIATURAS

AIC	<i>Akaike's Information Criterion</i> (Critério da Informação de Akaike)
ANATEL	Agência Nacional de Telecomunicações
AM	Amplitude Modulada
AoA	<i>Angle of Arrival</i> (Ângulo de Chegada)
ASK	<i>Amplitude Shift Keying</i> (Chaveamento de amplitude)
BIC	<i>Bayesian Information Criterion</i> (Critério da Informação Bayesiana)
BSS	<i>Blind Source Separation</i> (Separação Cega de Fontes)
BW	<i>Bandwidth</i> (largura de banda)
CDMA	<i>Code Division Multiple Accesses</i> (Acesso Múltiplo por Divisão de Código)
CEM	Compatibilidade eletromagnética
CFICA	<i>Convolutional FastICA</i> (Convolutivo FastICA)
CW	<i>Continuous Wave</i> (Onda Contínua)
DoA	<i>Direction of Arrival</i> (Direção de Chegada)
EC EMC	<i>Europe Community Electromagnetic Compatibility</i> (Comunidade Europeia de Compatibilidade Eletromagnética)
EEG	Eletroencefalograma
EM	Eletromagnéticas
ESPRIT	<i>Estimation of Signal Parameters via Rotational Invariance Technique</i> (Estimativa dos Parâmetros do Sinal via Técnica da Invariância Rotacional)
FCC	<i>Federal Communication Commission</i> (Comissão Federal de Comunicações)
fdp	Função Densidade de Probabilidade
FFT	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
FM	Frequência Modulada
fMRI	<i>Functional Magnetic Resonance Imaging</i> (Imagem por Ressonância Magnética Funcional)

LISTA DE ABREVIATURAS

FOBIUM	<i>Fourth Order Blind Identification of Under-determined Mixtures</i> (Identificação Cega de Quarta Ordem de Mistura Subdeterminadas)
FPGA	<i>Field-Programmable Gate Array</i> (Arranjo de Portas Programáveis em Campo)
FSK	<i>Frequency Shift Keying</i> (Chaveamento de frequência)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
HD TV	<i>High Definition TV</i> (TV de alta definição)
HSS	<i>Heart Sound Signals</i> (Sinais Sonoros do Coração)
ICA	<i>Independent Component Analysis</i> (Análise da Componente Independente)
IEM	Interferência eletromagnética
ITC	<i>Information Theoretic Criterion</i> (Critério Teórico da Informação)
InfoMax	<i>Information Maximization</i> (Maximização da Informação)
ISM	<i>Industrial, Scientific, and Medical</i> (Industriais, Científicas e Médicas)
JADE	<i>Joint Approximate Diagonalization of Eigenmatrices</i> (Diagonalização Aproximada Conjunta de “ <i>Eigenmatrices</i> ”)
KIC	<i>Kullback–Leibler Information Criterion</i> (Critério da Informação de Kullback-Leibler)
MDL	<i>Minimum Description Length</i> (Descrição do Comprimento Mínimo)
MEG	Magneto encefalograma
MUSIC	<i>MUltiple SIgnal Classification</i> (Classificação de Múltiplos Sinais)
OFCOM	<i>Office of Communications</i> (Escritório Federal de Comunicações da Europa)
PCA	<i>Principal Component Analysis</i> (Análise da Componente Principal)
PICA	<i>Pearson Independent Component Analysis</i> (Análise da Componente Principal baseado em sistema de Pearson)
PP	<i>Projection Pursuit</i> (Busca de Projeções)
QAM	<i>Quadrature Amplitude Modulation</i> (Modulação por amplitude em quadratura)
QPSK	<i>Quadrature Phase Shift Keying</i> (Chaveamento de fase em quadratura)

LISTA DE ABREVIATURAS

RBW	<i>Resolution BandWidth</i> (Largura de Faixa de Resolução)
RCD	Região de Campo Distante
RDS	Rádio Definido por <i>Software</i>
RF	Rádio Frequência
R&S	<i>Rohde & Schwarz</i>
SNR	<i>Signal-to-Noise Ratio</i> (Relação Sinal-Ruído)
SOBI	<i>Second-Order Blind Identification</i> (Identificação Cega de Segunda Ordem)
SOBIUM	<i>Second-Order Blind Identification of Underdetermined Mixtures</i> (Identificação Cega de Segunda Ordem de Mistura de Fontes Subdeterminadas)
STOTD	<i>Simultaneous Third-Order Tensor Diagonalization</i> (Diagonalização Simultânea de Tensores de Terceira Ordem)
TFBSS	<i>Time-Frequency Blind Source Separation</i> (Separação Cega de Fontes baseada em Tempo-Frequência)
USRP	<i>Universal Software Radio Peripheral</i>
VBW	<i>Video BandWidth</i> (Largura de Faixa de Vídeo)
VNA	<i>Vector Network Analyzer</i> (Analisador de Redes Vetorial)

Capítulo 1

1. Introdução

Em muitas situações práticas é necessário o uso de sensores para coletar informações seja devido à dificuldade de acesso seja devido à necessidade do monitoramento constante de variáveis [1]. Um grande número de sensores leva ao problema dos sinais fornecidos pelos sensores serem misturas dos sinais (fontes) desejados ou não. Além disso, devido à mobilidade das fontes a observação direta não é possível, bem como não é conhecida à forma como elas foram misturadas. Uma dessas situações ocorre, atualmente, no uso de equipamentos portáteis com tecnologia sem fio, aumentando significativamente a quantidade de fontes eletromagnéticas (desejadas e não desejadas) em ambientes fechados e abertos. O aumento da complexidade dos sistemas eletrônicos tem-se aumentado a preocupação com a redução dos níveis de sinais emitidos por fontes eletromagnéticas (EM) semelhantes e fisicamente muito próximas. Essas fontes podem ser causa de interferência eletromagnética (IEM), acompanhada de perda de conexões, consumo de energia e redução no nível de sinal desejado. Por outro lado, há a necessidade de uma maior seletividade dos aparelhos portáteis na seleção, por exemplo, do satélite de conexão dentre os vários disponíveis.

O aumento indiscriminado do número de fontes diz respeito a todos os setores, tais como comunicações, entretenimento e segurança. Por exemplo, o Serviço de Comunicação (OFCOM) da Comunidade Europeia tomou medidas especiais (de acordo com as diretivas EC EMC) para limitar o risco potencial da IEM com equipamentos sem fio durante os Jogos Olímpicos e Paralímpicos de Londres, em 2012 [2]. Uma das maiores dificuldades na separação e identificação de fontes EM é quando estas estão próximas uma das outras em um ambiente eletromagnético complexo.

Algumas informações, como por exemplo, potência do sinal, frequência de operação, nível de energia, podem ser obtidas dos sistemas por

tipos diferentes de transdutores (sensores) que contêm a informação sobre suas condições de operação. O avanço em técnicas de tratamento de sinais e em tecnologia de microprocessamento melhorou a extração dessas informações. Nesse sentido várias técnicas digitais de tratamento de sinais são usadas, tais como: filtragem, média, convolução, correlação, transformada rápida de Fourier [3], transformada *wavelet*, predição linear, métodos MUSIC, ESPRIT (métodos baseados em subespaços), correlação espectral, análise da componente independente, etc. Neste trabalho é usado o método da análise da componente independente [4].

A opção por esse método se deu em função da possibilidade de se obter informações sobre fontes EM sem nenhum conhecimento prévio de como elas foram geradas, de como é o ambiente onde estão inseridas ou de que maneira foram misturadas. Além disso, o método é de simples implementação, rápido e robusto. Pode trabalhar com dados nos domínios do tempo e da frequência, não exige grandes cuidados para coleta de dados e necessita apenas das informações obtidas pelos sensores de medição para separar e identificar fontes em ambientes eletromagnéticos complexos. Ele é um método relativamente novo que aponta como uma ferramenta promissora para tratar problemas de IEM.

O método de Análise em Componente Independente – ACI (ou do inglês *Independent Component Analysis* – ICA, como é mais conhecido) é um método de análise de sinais que se propõe à separação cega de fontes (do inglês, *Blind Source Separation (BSS)*) de sinais e é baseado no processamento de suas propriedades estatísticas. Distingue-se de outros métodos porque as componentes a serem encontradas são independentes estatisticamente e não-gaussianas. Ele tem sido aplicado para analisar problemas de IEM, principalmente em situações em que as fontes EM são sinais de amplitude e frequência diferentes e, dispostas separadamente uma das outras [5, 6, 7]. O ICA pode separar fontes que emitem sinal na forma conduzida ou irradiada, tendo o espectro de frequência como dado de entrada [8]. Estes dados são obtidos durante o processo de medição. É possível distinguir o ruído eletromagnético do ambiente, do sinal interferente e identificar fontes

irradiantes e/ou fontes conduzidas, além de sinais de onda contínua CW (*Continuous Wave*) e sinais modulados. No entanto, para os sinais com mesma amplitude e frequência, essa separação só se torna possível com a medição da fase dos sinais recebidos [9], situação estudada neste trabalho. Além disso, foram tratadas situações em que a diferença de frequência entre múltiplas fontes de sinais EM senoidais seja muito pequena, $\Delta F = 0,63\%$, que é muito menor do que os obtidos em [10] e [11]. Situação esta, que os métodos baseados em subespaços diminuem drasticamente seu desempenho, sendo necessários “deslocamentos artificiais” nas frequências para se conseguir uma boa separação [11]. Normalmente, as observações são obtidas a partir da saída de um conjunto de sensores (antenas) em que cada sensor recebe uma combinação diferente dos sinais fonte [12].

O problema da separação cega de múltiplas fontes tem sido fortemente estudado em aplicações de fontes de áudio, tais como a identificação de locutores [13, 14], a identificação de sons em ambientes reverberantes [15] e em fonocardiografia [16]. Neste trabalho, o ICA foi usado para separar sinais de múltiplas fontes de micro-ondas, as quais, naturalmente, têm propriedades diferentes de sinais de áudio. O ICA foi aplicado diretamente aos dados obtidos pela medição no domínio da frequência. A separação e identificação de fontes poderão ajudar na resolução de problemas já existentes como também prevenir futuros problemas. Nesse sentido pretende-se usar o ICA como uma ferramenta para separar e identificar fontes de sinais EM e assim inferir outras análises: O que é sinal desejado do que não é? Que faixas do espectro eletromagnético estão ocupadas e vazias? Qual a qualidade da separação das fontes? Qual a diferença mínima em frequência que o algoritmo pode separar? Para a solução dessas perguntas somente os casos cujo número de sensores é maior ou igual ao número de fontes foram estudados.

Um método de análise de sinais que tem a capacidade de distinguir fontes que estão fisicamente muito próximas uma das outras é uma ferramenta poderosa em aplicações, tais como segurança, rastreamento de pessoas (ou equipamentos) e melhorar o uso do espectro de frequência. A

detecção de sinais desejados e indesejáveis são objetivos procurados nos problemas de estimação da direção de chegada (DoA – *Direction of Arrival*), do ângulo de chegada (AoA – *Angle of Arrival*) e determinação da direção (DF – *Direction Finding*) [17].

O interesse em resolver problemas de separação, identificação e localização de fontes EM tem crescido entre os pesquisadores. Por exemplo, em sistemas de comunicação sem fio, em que se exige a necessidade de se estabelecer a intensidade ótima do campo transmitido para assegurar uma cobertura de rádio frequência (RF) adequada [18]. Em [19], é proposto um circuito para imitar o sistema de navegação de insetos, visando aumentar a sensibilidade de um arranjo de antenas e encontrar a direção de chegada. Outras opções usam a análise estatística como o método MUSIC [20] para estimar a DoA dos sinais ou ainda a estimativa dos parâmetros do sinal via técnica da invariância rotacional (ESPRIT) também proposto em [21].

O ICA é um método de separação cega de sinais que tem provado ser muito eficiente em vários cenários. Ele tem sido aplicado em vários problemas de engenharia, processos químicos [12], separação de áudio [14], processamento de imagem [22], comunicações [23], sensoriamento [24], medicina [4, 25], determinação da DoA [16, 26], detecção de falhas em motores de indução [27], separação de informações táteis por robôs [28], para citar algumas.

1.1 Contribuições do Trabalho

A seguir são apresentadas as contribuições deste trabalho:

1. Demonstração experimental da aplicabilidade do ICA e do coeficiente de correlação para tratar problemas de separação cega de fontes eletromagnéticas irradiantes;
2. Proposição do ICA como método de sensoriamento espectral, apontando suas vantagens e restrições.
3. Determinação dos limiares de frequência para aplicação do algoritmo FastICA para separação de sinais CW. Eles são válidos para qualquer uma

- das funções custo (g_1 , g_2 ou g_3), independente do FastICA com ortogonalização simétrica ou deflação.
4. Proposição de uma metodologia de coleta dos dados, para a aplicação do ICA, no caso de fontes muito semelhantes e espacialmente muito próximas, quando se usa os procedimentos tradicionais.
 5. Experimentação do ICA em situações mais complexas do que as apresentadas até então, como o caso de se ter fontes de sinais com as mesmas características, ou seja, sinal CW com mesma frequência e amplitude e que estejam muito próximas uma da outra ($d \ll \lambda_0$); situação em que os sinais dessas fontes tenham frequências diferentes ($\Delta F = 14\%$) ou muito próximas ($\Delta F = 0,63\%$), dispostas lado a lado ou uma atrás da outra, com polarizações diferentes, baixa relação sinal-ruído e originárias de fontes bem distintas.
 6. Demonstração experimental da estabilidade da resposta do ICA quanto ao posicionamento ou distância entre os sensores, diferença de polarização ou distância entre as antenas transmissora e receptora, bem como a sequência de combinação dos dados de entrada.
 7. Determinação, via simulação, que a função custo, g_3 , é a mais adequada ao primeiro teste de maximização da negentropia no algoritmo FastICA, nos casos estudados.

1.1 Objetivos

Os objetivos deste trabalho são:

- Aplicar o método de Análise da Componente Independente para separar fontes eletromagnéticas irradiantes com parâmetros idênticos e diferentes (em termos de amplitude e frequência);
- Propor procedimentos de medição e tratamento dos dados para fontes idênticas;
- Usar o coeficiente de correlação como parâmetro para determinar quantitativamente a precisão da resposta do ICA;
- Estudar a influência do posicionamento dos sensores na coleta de dados de entrada do ICA;

- Determinar a menor diferença em frequência que o ICA consegue separar e identificar dois sinais senoidais;
- Investigar a separação de múltiplas fontes com pequenas diferenças em frequência e com baixa relação sinal-ruído (≥ 2 dB);
- Trabalhar a separação de fontes produzidas por rádio definido por *software*;
- Estudar o uso do ICA no sensoriamento espectral de rádio frequência, em especial o espectro de TV (analógica e digital), visando aplicações de rádio cognitivo;
- Separar fontes de sinais modulados.

1.3 Organização da Tese

Os demais Capítulos estão organizados da seguinte forma:

O Capítulo 2 traz uma breve revisão bibliográfica sobre o ICA, destacando seus idealizadores, seus campos de aplicação, limitações e as conclusões do capítulo.

No Capítulo 3 é descrito o embasamento teórico sobre o tema de separação cega de fontes usando o ICA, tratando aspectos importantes para sua análise como independência estatística, não-gaussianidade, curtose e negentropia. É também apresentado o algoritmo programado (FastICA), algumas simulações e as conclusões do capítulo.

No Capítulo 4 são apresentados os resultados simulados para avaliar o algoritmo FastICA, descrição dos procedimentos de medição, problemas encontrados no tratamento dos dados para aplicação do ICA no caso de fontes idênticas e fisicamente muito próximas, análise da precisão do ICA por meio do coeficiente de correlação e as conclusões do capítulo.

O Capítulo 5 traz os resultados de vários ensaios realizados com antenas dipolo de meio comprimento de onda, a análise dos resultados, a adequação de procedimentos para aplicação do ICA em casos de fontes idênticas, a perspectiva de usar o ICA conjuntamente com o coeficiente de correlação para tomar decisões como a existência de fontes EM ativas ou passivas e as conclusões do capítulo.

No Capítulo 6 são expostos vários experimentos de separação e identificação de múltiplas fontes eletromagnéticas irradiantes usando o método ICA. Ele é aplicado a múltiplas fontes senoidais que apresentam valores de frequências bem distintos, próximos e muito próximos, sejam essas fontes produzidas por geradores de micro-ondas ou por rádio definido por *software* (RDS). Também são mostrados experimentos que visam à utilização do ICA para o sensoriamento do espectro de RF, para aplicações em rádio cognitivo e, separação de fontes de sinais FM (Frequência Modulada). Além disso, são exibidos os valores mínimos de diferença, em frequência, entre dois sinais senoidais que o FastICA é capaz de separar e identificar.

O Capítulo 7 traz as conclusões deste trabalho de tese e as perspectivas de continuação da pesquisa. No anexo A são mostrados o coeficiente de reflexão das antenas log-periódicas planares usadas nos experimentos do Capítulo 6, o código implementado em *Matlab*[®] por mim e a ferramenta que implementa o FastICA, disponível em [4].

Capítulo 2

2. Revisão Bibliográfica

Este Capítulo é dedicado à apresentação do desenvolvimento do método de análise da componente independente, aplicações e conceitos importantes para sua compreensão.

Na Seção 2.1 é feito um breve histórico da evolução do ICA, destacando seus idealizadores. A Seção 2.2 expõe várias aplicações que tem o ICA como base e, a Seção 2.3 trata de conceitos como não-gaussianidade, negentropia, curtose, etc.

2.1 Breve Histórico sobre o ICA

A história do método de Análise da Componente Independente (ICA) é relativamente recente. O seu marco inicial é atribuído ao trabalho de J. Héroult, C. Jutten e B. Ans de 1985, no qual os autores propuseram um método de separação de sinais biológicos baseado em modelos de redes neurais artificiais [4]. A motivação de tal trabalho decorreu de um problema biológico relacionado à codificação empregada pelo sistema nervoso central para a ativação muscular.

O cientista Pierre Comon foi um dos grandes responsáveis por despertar o interesse dos pesquisadores europeus pelo ICA. Em 1989, ele apresentou em um *workshop* o ICA como sendo um método de análise espectral de ordem elevada [29]. A partir dos resultados obtidos na década de 1950, por Darmois, Pierre Comon formalizou a ideia do ICA e mostrou como a independência estatística se insere na resolução dos problemas de separação de fontes. Essa contribuição teve papel fundamental no desenvolvimento de novos métodos de separação cega de fontes e no estudo das relações entre as diversas estratégias posteriormente desenvolvidas. Ao longo dos anos 80, as técnicas para ICA, estudadas principalmente por pesquisadores franceses,

tiveram pouca influência no cenário internacional. Na década de 1990, o ICA passou a ser mais investigado. Nesse período, destacaram-se os trabalhos de três pesquisadores Finlandeses: Karhunen, Oja e Hyvärinen, que permitiram interpretar o ICA como uma extensão não linear da consagrada técnica de Análise em Componentes Principais (PCA – *Principal Component Analysis*) [30]. Tal abordagem teve um papel fundamental no entendimento do ICA como um tema relevante em análise de dados, ou ainda, em análise multivariável. Já Hyvärinen contribuiu para o desenvolvimento de critérios baseados na maximização da não-gaussianidade [31].

Bell e Sejnowski, em 1995 [32], publicaram um artigo onde foi apresentado um algoritmo baseado no princípio de Maximização da Informação (*InfoMax*) que atraiu as atenções para a área de ICA por colocar o problema da separação cega de fontes dentro de uma estrutura neural baseada em princípios de Teoria da Informação [33]. Em 1996, o trabalho de S. Amari, A. Cichocki e H. H. Yang [34] permitiu melhorias na convergência do algoritmo de Bell e Sejnowski, por utilizar a aproximação do gradiente natural para minimizar a informação mútua. Somente em 1997, Hyvärinen, Karhunen e Oja apresentaram os algoritmos de ponto fixo e um algoritmo eficiente para problemas de grande escala que se baseou na maximização da não-gaussianidade dos sinais observados, o FastICA [35]. Dois trabalhos se destacam na apresentação dos conceitos estatísticos utilizados na resolução de problemas de separação cega por meio do ICA: o trabalho de Cardoso [36], que apresenta uma revisão do ponto de vista estatístico, das principais técnicas desenvolvidas até 1998; e o de Hyvärinen e Oja [37] que descreve de forma simples os principais conceitos do ICA. Em [38] encontra-se uma revisão sobre os métodos BSS e o ICA, destacando-se algoritmos BSS para modelos estáticos (misturas instantâneas), extensão de BSS e ICA incorporados com restrições de escassez ou de “não-negatividade” e, algoritmos BSS para modelos dinâmicos (misturas convolutivas).

Graças à criação do grupo de pesquisa BLISS (*Blind Source Separation and Applications*) na Europa em 1999, aumentou-se consideravelmente o número de trabalhos em BSS e ICA. O objetivo do grupo é

desenvolver trabalhos considerando misturas instantâneas e convolutivas; presença de ruído; métodos adaptativos e/ou não lineares. Os trabalhos abrangem as áreas de telecomunicações e engenharia biomédica. O projeto envolve cinco países incluindo Portugal (INESC), Finlândia (*Helsinki University of Technology*), França (*Institute National Polytechnique de Grenoble*), Alemanha (GMD) e Canadá (*McMaster University*) [33].

Em virtude dos avanços o ICA vem ganhando força no cenário de pesquisas internacionais e hoje é bastante usado nas mais diversas áreas, como será apresentado na próxima Seção.

2.2 Aplicações

O problema BSS aparece em muitos sistemas multisensor: arranjos de antenas em acústica ou eletromagnetismo; arranjo de sensores químicos; arranjo de eletrodos em eletroencefalografia, etc. Esse amplo conjunto de possíveis aplicações é, provavelmente, uma das razões para o sucesso do ICA [25]. Ele tem sido aplicado desde a medicina até aplicações financeiras [4].

O ICA, baseado em curtose, foi usado por Song Zhenfei *et al*, em [6], para diferenciar duas fontes de sinais simulados: uma fonte produz um sinal modulado em amplitude (AM) e a outra um sinal modulado em frequência (FM). Para validar o método os autores usaram osciladores, de frequências diferentes, conectados às antenas. O método ICA conseguiu distinguir os sinais das fontes irradiantes e separá-los do ruído ambiente com boa precisão. Toda análise foi feita no domínio da frequência.

Para melhorar a interação entre robôs e o homem, o ICA é usado em [28] de modo que o robô separe as fontes de informação tátil e devidamente interaja, simultaneamente, com as fontes de sinais táteis, sejam estas provenientes de um toque humano (carícia, aperto de mão, etc.), do ambiente ou de outro robô. O robô recebe a mistura das fontes táteis do ambiente por meio de um arranjo de sensores, que devem ser posicionados ao longo do corpo, e aplica o ICA para separar cada objeto (fonte) que o tocou. Para validar o método os autores realizaram experimentos com dados táteis reais (toque de duas mãos), adquiridos na saída de uma placa que contém 25 X 18 sensores de

pressão. Os sinais são separados em grupos e são identificadas as regiões tocadas e qual objeto tocou cada região.

O ICA é utilizado em [39] para separar o sinal de “*jamming*” do sinal de comunicação normal e usa um cumulante de quarta ordem para identificar o tipo de modulação. Os autores aplicam o algoritmo JADE para os sinais com modulação QPSK (*Quadrature Phase Shift Keying*), 2FSK (*Frequency Shift Keying*), 16QAM (*Quadrature Amplitude Modulation*) e 2ASK (*Amplitude Shift Keying*), ora estes sendo fontes, ora sendo o sinal interferente (“*jamming*”). Por exemplo, sinal fonte 16QAM e sinal “*jamming*” QPSK. Todas as situações investigadas, no artigo, são feitas via simulação. O sistema simula uma transmissão de duas fontes incidindo em arranjo de três antenas. Os sinais fontes e o ruído branco gaussiano possuem valores complexos. Os resultados são validados para sinais “*jamming*” com diferentes envelopes.

Melhorias no tratamento (qualidade) de imagens podem ser conseguidas com o uso do ICA complexo, como em [40]. Os autores aplicam o ICA a imagens de satélites capturadas por radar de abertura sintética polarimétrico (*Polarimetric synthetic aperture radar - POLSAR*) e conseguem melhorias significativas na intensidade e contraste das imagens.

Sinais de áudio podem ser separados usando o ICA, como em [33] e [41]. Primeiramente, as misturas instantâneas dos sinais foram geradas sinteticamente, a partir de sinais de áudio pré-gravados de falas do filme *Harry Potter*. Essa mistura foi analisada pelo ICA e o resultado foi à separação dos sinais fontes com amplitude e em ordem diferentes. Mesmo assim a inteligibilidade dos sinais estimados foi muito próxima dos sinais originais. Em [41] os sinais de voz são adicionados de ruído branco e o algoritmo é implementado usando redes neurais. Outros trabalhos usam o ICA para localização de múltiplas fontes acústicas, como em [13, 15], onde os autores utilizam os coeficientes da matriz de separação como base para estimar a direção de chegada dos sinais sonoros. Eles se utilizam de arranjo de microfones. Uma diferença básica, entre os trabalhos, está na quantidade de fontes e de sensores (microfones): em [13] são utilizadas três fontes e três

microfones; em [15] são usadas duas fontes e se usa um arranjo esférico de vinte quatro microfones, em que uma maior precisão na estimativa da direção de chegada combinando o ICA com o método de “recuperação esparsa” (*sparse recovery (SR) method*) é obtida. Outra aplicação do ICA para estimar a direção de chegada de sinais de áudio pode ser vista em [26].

Uma versão modificada do ICA, o cICA (*constrained Independent Component Analysis*) [42], é aplicado para identificar um sinal de comunicação desejado (sinal com modulação QPSK) dentro de uma mistura de sinais que chegam num arranjo linear uniforme de sensores. Os autores consideram conhecer previamente a exata direção da fonte desejada, o diagrama espacial dos sensores e que só interessa uma componente independente. Com essas restrições os autores afirmam conseguir uma redução no número de componentes encontradas pelo ICA e aumentar seu desempenho. Todos os dados usados no artigo são obtidos por simulação computacional. Nas simulações são usados quatro sinais QPSK e um arranjo de quatro sensores.

Localizar e identificar fontes irradiantes distantes uma da outra é o objetivo dos autores em [6, 18]. A partir de um conjunto de dados medidos devem-se retirar informações do número, posição e intensidade das fontes (sinais AM). Para resolver esse problema usou-se o método ICA conjuntamente com um modelo de propagação eletromagnética de *Okumura-Hata*. A identificação e localização de fontes são obtidas processando os valores de campo provenientes de um conjunto de 16 sensores, posicionados no espaço livre, e resolvendo um problema inverso. Os valores de campo medidos são usados para identificar o número e a frequência das fontes eletromagnéticas posicionadas dentro da região analisada por meio do ICA. Uma vez que o número e a intensidade das fontes desconhecidas foram determinados pelo ICA, a posição das fontes é calculada por outro procedimento no qual uma função custo é minimizada. Nas situações estudadas a relação sinal ruído é superior a 11 dB.

O ICA foi aplicado para discriminar tecidos normais e lesionados em mamogramas em [43]. O exame de mamografia consiste em um conjunto de informações heterogêneas de diversas fontes (tecidos, filme, características do

mamógrafo, etc.). Essas informações compõem uma imagem mamográfica que pode ser descrita como uma combinação linear de um conjunto de imagens-base estatisticamente independentes entre si. O ICA foi usado na extração dos parâmetros das imagens e depois uma rede neural foi usada para classificar a região como normal ou lesionada. Destaca-se que os melhores resultados foram obtidos com a aplicação do método ICA com a maximização da negentropia.

Outras aplicações do ICA são discutidas por Aapo Hyvärinen *et al*, em [4]. Por exemplo, encontrar fatores escondidos em dados financeiros e imagens do cérebro: como no caso do eletroencefalograma (EEG) e do magnetoencefalograma (MEG), que são gravações de campos elétricos e magnéticos de sinais que emergem de correntes neurais dentro do cérebro. Ele também pode ser usado para aplicações biomédicas [44]. Em telecomunicações, o ICA pode ser usado para detecção de multiusuário e comunicação CDMA [25, 45].

Em [46], Sidcley P. Gomes *et al* fizeram uma análise de um eletroencefalograma na busca de detectar uma descarga frontal no cérebro em pacientes que sofrem de um tipo de epilepsia juvenil. Essa informação foi retirada do EEG usando o método ICA. O ICA foi usado para separar as descargas “*epileptiforme dos artefatos*” e outras fontes de sinais elétricos provenientes do cérebro. Os sensores usados, para capturar os sinais, foram antenas dipolos, implantados na parte frontal do cérebro do paciente.

O uso do método ICA em aplicações de compatibilidade e interferência eletromagnética conduzida ainda é pouco difundido, mas vem crescendo nos últimos anos. Por exemplo, em [8] esse método foi utilizado para separar três fontes de interferência eletromagnética conduzida (*crosstalk*). Nesse caso, o método separa as fontes de interferência em pares de fios transados usados em linhas de transmissão de telecomunicações. Os autores injetaram, na extremidade de três pares de fios, sinais conhecidos com frequências e amplitudes bem distintas. Cada par de fios recebeu um sinal distinto. Na outra extremidade mediram os sinais recebidos e perceberam que eles sofreram interferência mútua dos outros sinais, ou seja, *crosstalk*. Por

meio do ICA eles conseguiram obter os sinais que foram introduzidos em cada par de fios. Toda análise foi feita no domínio do tempo.

A versatilidade do ICA permite usá-lo em situações muito distintas, como em [12], onde ele é usado para identificar os sinais acústicos úteis emitidos no processo de corrosão do alumínio. No processo é usada a transformada *wavelet* para retirar o ruído das componentes independentes encontradas pelo ICA. Em [47], o ICA é usado para isolar os efeitos do mascaramento energético devido à sobreposição espectral na percepção da fala de multilocutor. Nesse estudo foram usadas duas vozes masculinas misturadas por uma matriz de valores complexos. Em [16], Abdullan K. Khan *et al* apresentaram um sistema de *hardware* utilizando o ICA, no domínio da frequência, juntamente com a estimativa da direção de chegada (DoA) e técnicas “*beamforming*” de supressão de ruído para melhorar a qualidade dos Sinais Sonoros do Coração (HSS – *Heart Sound Signals*) e ajudar o diagnóstico dos médicos. Já em [27] o ICA é usado com a FFT (*Fast Fourier Transform*) para resolver problemas com a detecção de faltas dos sinais de corrente do estator, em motores de indução. A ideia é determinar a assinatura de falta de fase do motor.

Num processo industrial as informações do fluxo das três fases: óleo, água e gás, são obtidos pelo ICA, por meio dos dados de sensores de condutância multicanal [48].

Existem métodos que são usados para estimar somente o número de fontes (principalmente fontes que tem distribuição Gaussiana) e não quais são as fontes [49, 50]. Eles são denominados métodos baseado em critérios teóricos da informação (*Information Theoretic Criterion* – ITC) e muito usados para processamento de imagem fMRI (*Functional Magnetic Resonance Imaging*) e informações táteis [28], para determinar o número de sensores a serem usados num arranjo e assim evitar que se utilize mais ou menos sensores na determinação das fontes. Os métodos ITC incluem o critério de informação de Akaike (*Akaike’s Information Criterion* – AIC), o critério da informação de Kullback-Leibler (*Kullback–Leibler Information Criterion* – KIC), o critério de descrição do comprimento mínimo (*Minimum Description Length* – MDL), o

critério da informação Bayesiana (*Bayesian Information Criterion* – BIC) e uma aproximação de Laplace para o critério Bayesiano baseada no modelo de evidências [51]. Todos exigem grande esforço computacional e são pouco difundidos na literatura que trata de problemas relacionados à BSS. Não é objetivo, desta tese, estudar tais métodos, mas tão somente destacar a sua existência.

As áreas de aplicação do ICA são bem variadas, porém, quanto ao estudo de interferência eletromagnética têm-se poucos trabalhos. Nos casos em que se têm estudos de separação de fontes irradiantes, por exemplo, as fontes são dispostas em situações relativamente fáceis para a ação do ICA. Observa-se que o ICA não foi avaliado para o caso de se ter fontes de sinais com as mesmas características, ou seja, fontes irradiantes, alimentadas com mesmo sinal (mesmas frequências e mesmas amplitudes) e que estejam muito próximas uma das outras ($d \ll \lambda_0$ – sendo λ_0 o menor comprimento de onda dos sinais fontes). Outro caso é a situação em que os sinais de múltiplas fontes tenham frequências diferentes, mas de valores muito próximos, dispostas lado a lado ou colinearmente. Também não é dada ênfase ao posicionamento dos sensores; ao limite da diferença em frequência que o ICA pode separar; ao nível mínimo de SNR em que se consegue separação e identificação com o ICA; e aplicação em sensoriamento espectral. Portanto, este trabalho se destina a explorar o ICA nessas situações.

2.3 Restrições para Aplicação do ICA

As restrições ou critérios desenvolvidos para aplicação do ICA exploram direta ou indiretamente as hipóteses de independência e não-gaussianidade das fontes [25, 37]. As restrições, a seguir, são importantes tanto do ponto de vista conceitual do método quanto da sua aplicação prática.

➤ *As componentes são estatisticamente independentes entre si*

Por definição, o método proposto para separação de fontes pressupõe que as componentes que originam a mistura sejam estatisticamente independentes entre si.

Matematicamente, a independência estatística, entre variáveis aleatórias x, y, z, \dots , é definida quando a função densidade de probabilidade (fdp) conjunta das variáveis é igual ao produto das fdp's marginais, ou seja,

$$f_{x,y,z,\dots}(x, y, z, \dots) = f_x(x)f_y(y)f_z(z) \dots \quad (2.1)$$

Em que, $f_{x,y,z,\dots}(x, y, z, \dots)$ representa a fdp conjunta das variáveis aleatórias x, y, z, \dots , e $f_x(x)$, $f_y(y)$ e $f_z(z)$ representam a fdp marginal das variáveis aleatórias x, y e z .

As variáveis aleatórias x e y são ditas independentes se a ocorrência de y não traz qualquer informação sobre a variável aleatória x [52].

➤ As componentes independentes devem apresentar distribuições não gaussianas

Uma das principais restrições para a realização do método ICA é que os sinais fontes apresentem fdp não gaussiana ou que no máximo uma delas seja gaussiana. A fdp conjunta de duas variáveis gaussianas estatisticamente independentes s_1 e s_2 , com média zero e variância unitária, é dada por [4]:

$$f_{s_1 s_2}(s_1, s_2) = \frac{1}{2\pi} e^{-\frac{s_1^2 + s_2^2}{2}} = \frac{1}{2\pi} e^{-\frac{\|\mathbf{s}\|^2}{2}}, \quad (2.2)$$

em que, $\|\mathbf{s}\|^2$ é a norma do vetor aleatório $\mathbf{s} = (s_1, s_2)$.

No modelo do ICA, que será descrito na Seção 3.2, existe uma matriz \mathbf{A} denominada matriz de misturas e um vetor de misturas aleatórias \mathbf{x} . A matriz \mathbf{A} é responsável por combinar linearmente os sinais provenientes das fontes originais e o vetor \mathbf{x} por guardar a mistura destes. Na prática os elementos do vetor \mathbf{x} (x_1, x_2, \dots, x_n), são os sinais capturados por cada sensor no ambiente em que se deseja separar as fontes de sinais. Assumindo que a matriz \mathbf{A} seja ortogonal, tem-se que $\mathbf{A}^T = \mathbf{A}^{-1}$. Pode-se expressar a fdp dos sinais misturados x_1 e x_2 por [43]:

$$f_{\mathbf{x}}(x_1, x_2) = \frac{1}{2\pi} e^{-\frac{\|\mathbf{A}^T \cdot \mathbf{s}\|^2}{2}} |\det \mathbf{A}^T|. \quad (2.3)$$

Como \mathbf{A} é ortogonal, tem-se também que $\|\mathbf{A}^T \cdot \mathbf{s}\|^2 = \|\mathbf{s}\|^2$ e que $|\det \mathbf{A}^T| = 1$, portanto,

$$f_{\mathbf{x}}(x_1, x_2) = \frac{1}{2\pi} e^{-\frac{\|\mathbf{s}\|^2}{2}}. \quad (2.4)$$

Para variáveis gaussianas (x_1 e x_2), uma matriz de mistura ortogonal não altera a fdp conjunta, ou seja, a matriz \mathbf{A} sequer aparece na fdp da mistura. Isso ocorre porque variáveis gaussianas descorrelacionadas são, necessariamente, independentes. Assim, pode-se dizer que a matriz \mathbf{A} não pode ser estimada, se mais do que uma das fontes originais for gaussiana. Graficamente (Figura 1), a distribuição conjunta de s_1 e s_2 é praticamente isotrópica, não sendo alterada quando submetida a uma rotação. Assim, a fdp não contém nenhuma informação sobre a matriz \mathbf{A} , o que impede de estimá-la somente a partir das distribuições de x_1 e x_2 .

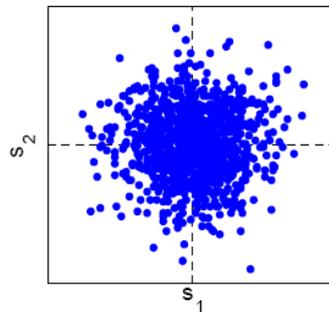


Figura 1 - Distribuição conjunta de duas variáveis gaussianas independentes [43].

Vários métodos foram desenvolvidos, baseados no princípio de que para variáveis não gaussianas a independência é suficiente para garantir que as fontes estimadas serão distintas.

Uma condição tomada, apenas para simplificar o modelo básico do ICA, considera que a matriz \mathbf{A} é quadrada, ou seja, o número de componentes independentes que se deseja estimar é o mesmo que o número de dados observados. Porém, essa condição pode ser relaxada e é possível estudar os casos em que o número de fontes e misturas sejam diferentes, como em [4].

Um teorema importante, proposto por Pierre Comon [53], deve ser observado. É o teorema da *Separabilidade do modelo ICA*, em que o modelo $\mathbf{x} = \mathbf{A}\mathbf{s}$ (modelo usado para o ICA) é separável se e somente se a matriz \mathbf{A} possuir posto completo, e no máximo, um elemento do vetor aleatório \mathbf{s} for

gaussiano [31]. No caso em que se tenham mais misturas (medições) do que fontes é possível omitir misturas redundantes, recaindo-se no caso anterior. No entanto, se o número de fontes for maior que o de misturas, encontrar a matriz de misturas não resolve o problema de estimação em componentes independentes, que se torna consideravelmente mais complexo.

Existem vários critérios de independência que podem ser usados na separação cega de fontes, tais como: Informação mútua (conceito relacionado à teoria da informação); estatísticas de ordem superior (aplica-se o conceito de cumulante); correlação não linear; maximização da não-gaussianidade; máxima verossimilhança, para citar alguns [54]. Em geral o ICA usa os critérios de cumulante e maximização da negentropia. Adotou-se nesse trabalho, a maximização da negentropia, por ser uma medida estatisticamente mais robusta e menos susceptível a “*outliers*”.

A maximização da não-gaussianidade pode ser compreendida por meio do teorema central do limite [4]. Segundo o teorema, a função densidade de probabilidade da soma de variáveis aleatórias independentes e identicamente distribuídas, tende à de uma variável gaussiana [43]. Portanto, de certa forma, a fdp da soma de duas variáveis aleatórias independentes e identicamente distribuídas está mais “próxima” de uma distribuição gaussiana do que qualquer uma das variáveis originais (Figura 2) [54]. Sob a óptica desse teorema é de se esperar que as misturas sejam mais próximas a gaussianas se comparadas com as fontes isoladamente, considerando-se que elas sejam identicamente distribuídas. Dessa forma, ao localizar máximos locais de uma medida de não-gaussianidade, estão sendo encontradas as componentes independentes. Logo, uma tentativa de ajustar \mathbf{W} (matriz de separação dos sinais) fundamenta-se justamente na recuperação da não-gaussianidade das estimativas das fontes [55].

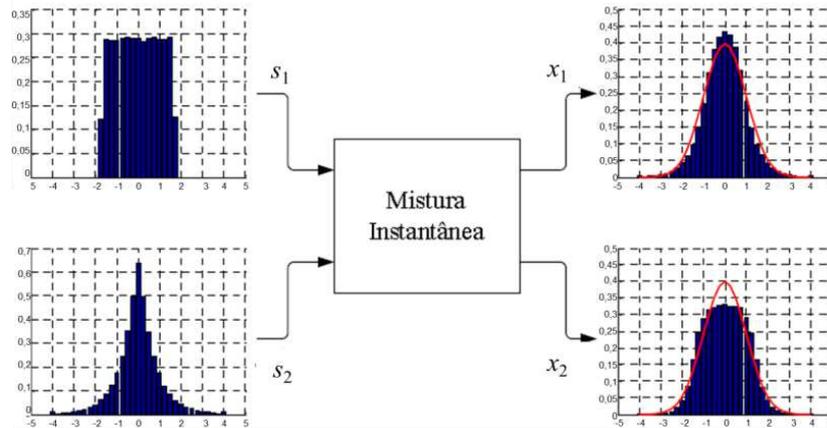


Figura 2 - Exemplo de mistura de duas fontes independentes, uma com distribuição uniforme (s_1), e outra com distribuição laplaciana (s_2). Nota-se, intuitivamente, que as observações (x_1 e x_2) possuem um perfil (contorno dos histogramas) mais próximas ao de uma variável aleatória gaussiana do que as variáveis originais [54].

Em outras palavras é possível criar uma sistemática na qual se determina a localização das componentes que maximizam a não-gaussianidade. A componente independente será encontrada exatamente quando \mathbf{y} (vetor de componentes independentes) se tornar o mais distante possível de uma fdp gaussiana.

A não-gaussianidade de uma variável aleatória pode ser medida pelos parâmetros: curtose e pela negentropia [4, 43, 54 e 55].

- Curtose – é um parâmetro estatístico de quarta ordem que, para o caso de média nula, é definido pela expressão (2.5),

$$K(x) = E\{x^4\} - 3(E\{x^2\})^2. \quad (2.5)$$

A curtose é muito utilizada em diversas áreas, devido à sua simplicidade e propriedades [33]. É comum o uso de uma versão normalizada da curtose, como visto na expressão (2.6), na qual a curtose foi dividida pelo quadrado da variância, $E(\{x^2\})^2$.

$$\kappa_n(x) = \frac{E\{x^4\}}{E(\{x^2\})^2} - 3. \quad (2.6)$$

Para o caso dos dados terem média zero e variância unitária, ou seja, $E\{x^2\} = 1$, a expressão da curtose normalizada se resume a:

$$\kappa_n(x) = E\{x^4\} - 3. \quad (2.7)$$

A curtose normalizada é nula para distribuições gaussianas e, na prática, é não nula para distribuições não gaussianas. Dessa forma, ela pode ser usada como medida de não-gaussianidade [4].

A curtose de uma variável aleatória pode ser positiva, negativa ou nula, sendo assim é usual classificar as distribuições com relação aos valores de suas curtoses: caso $K(x) > 0$, diz-se que x possui distribuição super-gaussiana ou *leptokúrtica*. Variáveis super-gaussianas tem uma distribuição mais concentrada em torno da média e caudas mais longas que a distribuição gaussiana com mesma média e variância [43]. Um exemplo é a distribuição de Laplaciana (Figura 3.a); caso de $K(x) < 0$ diz-se que x possui distribuição sub-gaussiana, ou *platokúrtica*. Essas variáveis apresentam uma fdp mais espalhada pelo domínio da variável, por exemplo, a fdp uniforme (Figura 3.b). Na Figura 3 é exemplificado os histogramas de uma distribuição super-gaussiana e sub-gaussiana, respectivamente.

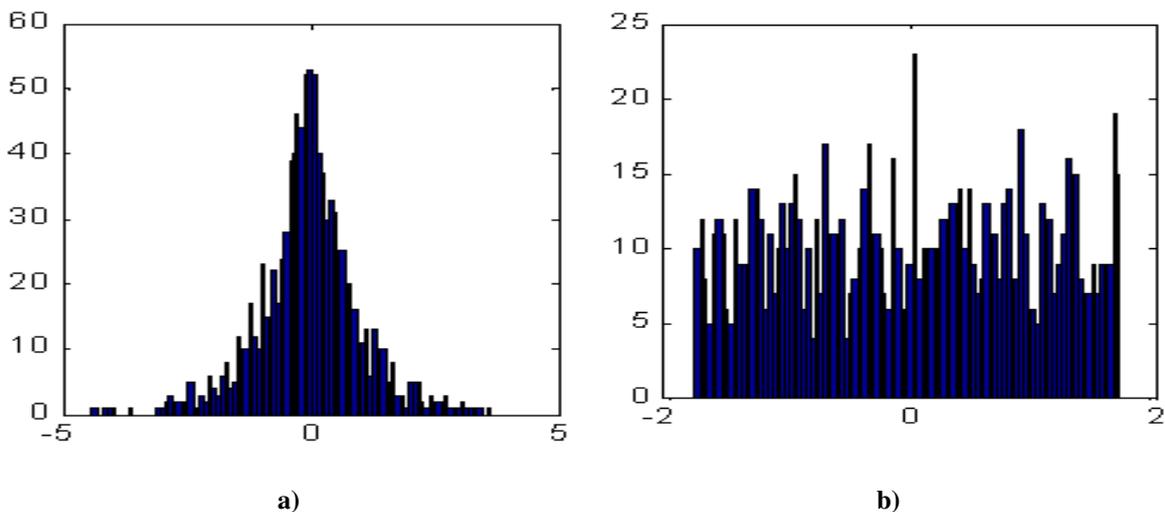


Figura 3 – a) Histograma de uma variável super-gaussiana; b) Histograma de uma variável sub-gaussiana [43].

As componentes independentes são encontradas maximizando ou minimizando a curtose, de acordo com o algoritmo de otimização empregado.

Uma limitação da curtose como medida de não-gaussianidade se deve ao fato dela ser sensível à “outliers”, também designados por observações anormais ou extremas ou aberrantes. Os “outliers” podem gerar resultados falsos, pois fazem com que o valor da curtose seja alterado consideravelmente. Outro limitante está no fato da curtose ser baseada em uma estatística de

quarta ordem, isso exige um número elevado de amostras do sinal para que sua estimativa seja confiável. Porém, a facilidade e simplicidade computacional da curtose normalizada a tornam uma medida atrativa para aplicação em diversos algoritmos.

- Negentropia – é uma medida quantitativa de não-gaussianidade baseada na entropia diferencial de uma variável aleatória. Essa medida fornece métodos não sensíveis a “*outliers*” como aqueles baseados em curtose [43, 55].

A entropia é um conceito fundamental da teoria da informação e mede o grau de informação que pode ser obtida através da observação de uma variável. Neste sentido, quanto mais imprevisível for a variável observada, maior será sua entropia [56].

Seja um vetor aleatório \mathbf{x} com uma fdp $f_{\mathbf{x}}(\cdot)$, a entropia diferencial é definida como [56]:

$$h(\mathbf{x}) = - \int f_{\mathbf{x}}(\xi) \log(f_{\mathbf{x}}(\xi)) d\xi. \quad (2.8)$$

Um resultado muito importante da teoria da informação é que a distribuição mais imprevisível, menos estruturada, ou seja, com maior entropia, é a distribuição gaussiana em relação a todas as outras de mesma variância. Portanto, pode-se considerar essa característica para o uso da entropia como uma medida de não-gaussianidade.

Matematicamente negentropia é uma medida normalizada da entropia diferencial, conforme a expressão (2.9).

$$J(x) = h(x_{gauss}) - h(x). \quad (2.9)$$

Em que x_{gauss} é uma variável aleatória com distribuição gaussiana de mesma matriz de correlação e covariância que a variável x .

Uma vez que a entropia de uma variável aleatória é máxima para a distribuição gaussiana, a negentropia sempre assumirá valores maiores ou iguais à zero, ocorrendo à igualdade somente quando x possuir distribuição normal (gaussiana). O conceito pode ser estendido diretamente para um vetor \mathbf{y} de variáveis aleatórias, sendo $J(\mathbf{y}) = h(\mathbf{y}_{gauss}) - h(\mathbf{y})$, onde \mathbf{y}_{gauss} representa

um vetor aleatório com distribuição gaussiana e matriz de covariância igual à de \mathbf{y} [54].

A vantagem de se usar essa medida consiste no fato dela ser bem justificada estatisticamente e ser, de certa forma, um estimador ótimo da não-gaussianidade [57]. O maior problema de usá-la é devido a sua complexidade computacional, pois exige o conhecimento ou a estimativa (provavelmente não paramétrica) da fdp. Porém, é possível fazer aproximações muito boas que podem ser aplicadas na prática [30, 43].

Hyvärinen [4] determinou uma aproximação para a negentropia (expressão (2.9)) e obteve a expressão (2.10), em que $F_i(x)$ é uma função não polinomial. Uma vez que funções polinomiais tornam a aproximação suscetível a “outliers”.

$$J(x) \approx \frac{1}{2} \sum_{i=1}^n (E\{F_i(x)\})^2. \quad (2.10)$$

Embora essa aproximação não seja precisa, a expressão (2.10) pode ser usada como medida de não-gaussianidade, no sentido de obter o valor mínimo, quando x tiver distribuição gaussiana.

Os resultados produzidos pelo ICA não garantem que o sinal estimado terá mesma amplitude e mesma fase dos sinais originais e ainda, que eles sejam estimados na mesma ordem. Esse fato está relacionado à própria característica de construção da matriz \mathbf{A} de não se ter conhecimento dos seus elementos e, do vetor \mathbf{s} , pois possui elementos aleatórios [4].

2.4 Conclusão do Capítulo

Neste Capítulo foi apresentado um breve histórico da evolução do ICA, destacando seus idealizadores. Foram expostos vários tipos de aplicação do ICA, que demonstram o potencial deste método para problemas de separação de fontes. Também se abordou alguns conceitos importantes para compreensão do método, como por exemplo, conceitos como não-gaussianidade, curtose e negentropia.

Apesar do ICA, ter sido aplicado a várias áreas, têm-se poucos estudos relacionados com interferência eletromagnética. Nos casos estudados

de separação de fontes irradiantes, as aplicações são para casos em que fontes possuem frequências e amplitudes diferentes. Observa-se que o ICA não foi avaliado para o caso específico de se ter fontes de sinais com as mesmas características, ou seja, fontes irradiantes, alimentadas com mesmo sinal (mesma frequência e mesma amplitude, por exemplo, redes com uma única frequência) e que estejam muito próximas uma das outras ($d \ll \lambda_0$). Outro caso é a situação em que os sinais dessas fontes tenham frequências diferentes, mas de valores muito próximos. Também não é dada ênfase ao posicionamento dos sensores ou a identificação de elementos passivos em torno das fontes irradiantes, assim, vê-se a necessidade de trabalhar com o ICA nessas condições.

A aplicação do ICA é restrita a fontes que sejam estatisticamente independentes; não tenham distribuição gaussiana (ainda aplicável para o caso de ser ter uma única fonte gaussiana). O uso da negentropia, como parâmetro de maximização da não-gaussianidade, oferece uma medida mais robusta ao efeito de “*outliers*”.

Como os elementos da matriz \mathbf{A} e do vetor \mathbf{s} possuem elementos aleatórios o ICA não garante que o sinal estimado terá mesma amplitude e mesma fase dos sinais originais e que eles sejam estimados na mesma ordem. Por exemplo, os sinais fontes s_1 e s_2 deveriam naturalmente ser recuperados como componentes y_1 e y_2 , respectivamente. Porém, pode acontecer do sinal s_1 e s_2 serem recuperados como componentes y_2 e y_1 , respectivamente. Portanto, em ordem diferente.

Capítulo 3

3. O Método de Análise da Componente Independente – ICA

Este Capítulo trata da definição e embasamento matemático envolvido na análise da componente independente.

Na Seção 3.1 é apresentada a definição do ICA. A Seção 3.2 traz a descrição matemática do modelo do ICA usado neste trabalho. Na Seção 3.3 são discutidas as funções objetivo usadas nos algoritmos que implementam o ICA. Na Seção 3.4 são apresentadas as conclusões do capítulo.

3.1 Definição

O método de análise da componente independente é um método de análise de sinais que usa técnicas estatísticas para separação cega de fontes, tendo por base um conjunto de sinais medidos (observados). O ICA pode recuperar um sinal desconhecido a partir de uma combinação (mistura) linear deste com outros. Para isso não é necessário o conhecimento prévio do processo de mistura dos sinais ou das fontes originais.

3.2 Descrição Matemática do ICA

Em muitas situações práticas é necessário o uso de sensores para coleta de informações, e nestes casos decorre que os sinais recebidos dos sensores serem misturas dos sinais (fontes) desejados. Soma-se a isso, em geral, os casos em que não é possível observar as fontes diretamente, ou se conheça à forma como as fontes foram misturadas. Nesse cenário deseja-se separar as fontes sem conhecê-las. Os problemas em que não se têm ou se têm com escassez, conhecimento com relação às fontes e o processo de mistura dos sinais são conhecidos como problemas de Separação Cega de Fontes (BSS).

Ao longo dos anos, vários métodos foram propostos para resolver o problema de separação cega de fontes como o PCA (*Principal Component Analysis*), busca de projeção (PP – *Projection Pursuit*) e Curvas de Pearson [4]. Eles usam critérios de busca das fontes pouco robustas (sinais apenas não correlacionados), são complexos e restritivos a algumas aplicações. O ICA, que é também um método para resolver problemas de BSS, foi escolhido por superar essas dificuldades, se adaptar bem ao problema de interferência eletromagnética e possibilitar análise dos dados, estejam eles no domínio do tempo ou no domínio da frequência. Por isso, o ICA é um dos métodos mais utilizados para a realização de separação cega de fontes.

Para definir rigorosamente o método ICA, pode-se usar um modelo estatístico de "variáveis latentes" [4]. Variáveis latentes significa que elas não podem ser diretamente observadas. Considere que sejam observadas n variáveis aleatórias x_1, x_2, \dots, x_n , modeladas como combinações lineares de n variáveis aleatórias s_1, s_2, \dots, s_n :

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n, \text{ para todo } i = 1, \dots, n. \quad (3.1)$$

Em que a_{ij} , $i, j = 1, \dots, n$, são coeficientes reais. Por definição, os s_i são estatisticamente independentes entre si. Este é o modelo básico do ICA.

O modelo do ICA é um modelo generativo, o que significa que ele descreve como os dados observados são gerados por um processo de mistura das componentes s_j .

A ICA de um vetor aleatório $\mathbf{x} = [x_1, x_2, \dots, x_M]^T$ consiste na determinação de uma transformação linear $\mathbf{y} = \mathbf{W}\mathbf{x}$ de tal maneira que os elementos do vetor aleatório $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$ otimizem uma função custo $\psi(\mathbf{y})$, denominada função contraste, que expressa uma medida de independência [31]. O modelo do ICA é baseado na combinação linear dos sinais fontes. Eles são relacionados por uma matriz de misturas \mathbf{A} . Matematicamente o modelo é descrito, na forma matricial, pela expressão (3.2) [4, 7].

$$\mathbf{x} = \mathbf{A}\mathbf{s}. \quad (3.2)$$

Em que, \mathbf{x} é o vetor de medidas aleatórias, cujos dados podem estar no tempo ou na frequência [26]. Na prática, ele corresponde aos sinais obtidos em cada sensor que captura a mistura dos sinais. Em (3.2) \mathbf{A} é uma matriz de misturas constante de dimensão $M \times N$, com elementos a_{ij} desconhecidos e \mathbf{s} é o vetor aleatório das fontes originais. Os elementos de $\mathbf{s} = [s_1, s_2, \dots, s_N]^T$ são estatisticamente independentes entre si e não apresentam distribuição gaussiana. Caso exista apenas um dos elementos de \mathbf{s} com distribuição gaussiana, o ICA será capaz de separá-lo dos demais [25, 43]. Existindo dois ou mais elementos de \mathbf{s} com distribuição gaussiana, o resultado obtido pelo ICA não corresponderá à realidade, pois isso fere a condição inicial para aplicação deste método.

O modelo do ICA para o caso de se ter três fontes [4, 43], por exemplo, pode ser escrito como:

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) + a_{13}s_3(t), \\ x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) + a_{23}s_3(t), \\ x_3(t) &= a_{31}s_1(t) + a_{32}s_2(t) + a_{33}s_3(t). \end{aligned} \quad (3.3)$$

Assume-se que os coeficientes a_{ij} da matriz de mistura são diferentes o suficiente para fazer a matriz \mathbf{A} inversível. Portanto, existe uma matriz \mathbf{W} com coeficientes w_{ij} que podem ser usados para separar os sinais.

O objetivo do ICA é encontrar o sinal original a partir dos sinais medidos (misturados). Assim, se uma matriz $\mathbf{W} = \mathbf{A}^{-1}$ existe, o sinal original é dado por:

$$\mathbf{s} = \mathbf{W}\mathbf{x}. \quad (3.4)$$

Para o caso de três fontes de sinais, têm-se:

$$\begin{aligned} s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + w_{13}x_3(t), \\ s_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + w_{23}x_3(t), \\ s_3(t) &= w_{31}x_1(t) + w_{32}x_2(t) + w_{33}x_3(t). \end{aligned} \quad (3.5)$$

No sistema apresentado na expressão (3.5) não são conhecidos os valores dos elementos de \mathbf{s} e \mathbf{W} , portanto, existe a necessidade da procura de um artifício para resolver o sistema. A solução é considerar que exista um vetor de sinais \mathbf{y} estatisticamente independente na expressão (3.6), que corresponderá aos sinais originais (vetor \mathbf{s}).

$$\mathbf{y} = \mathbf{W}\mathbf{x}. \tag{3.6}$$

Uma vez determinados os valores de w_{ij} , podem-se determinar os valores do vetor \mathbf{y} que conseqüentemente corresponderão aos valores do vetor de sinais original (idealmente $\mathbf{y} = \mathbf{s}$). Assim,

$$\begin{aligned} y_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + w_{13}x_3(t), \\ y_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + w_{23}x_3(t), \\ y_3(t) &= w_{31}x_1(t) + w_{32}x_2(t) + w_{33}x_3(t). \end{aligned} \tag{3.7}$$

De maneira resumida aplicar o ICA a um vetor de misturas lineares e instantâneas \mathbf{x} é encontrar uma matriz de separação \mathbf{W} de tal forma que os elementos do vetor aleatório $\mathbf{y} = \mathbf{W}\mathbf{x}$, sejam tão estatisticamente independentes quanto possível. A estimativa da matriz \mathbf{W} é realizada por meio da otimização de uma função objetivo que usa as propriedades estatísticas dos sinais. Na Figura 4 é apresentado o diagrama esquemático do método ICA.

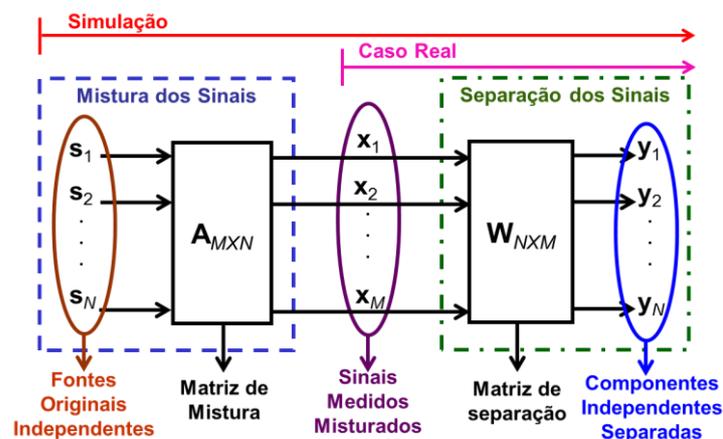


Figura 4 - Diagrama esquemático de mistura e separação do modelo do ICA, modificado de [58].

A abordagem adotada assumirá, inicialmente, que o modelo é linear, generativo e com bases completas, ou seja, há N fontes e N dados observados. Em seguida, será estudado o caso em que se tem N fontes e M dados

observados, conhecido como caso de misturas sobre determinadas. Todos os dados são considerados valores reais. Esse modelo básico é também chamado de instantâneo, uma vez que se supõe que não há atrasos nas misturas [4].

3.3 Funções Objetivo (ou Funções Custo)

As principais funções custo para estimativa das componentes independentes são baseadas na maximização da não-gaussianidade das variáveis medidas, minimização da não-gaussianidade da informação mútua e estimativa da máxima verossimilhança [33].

As funções custo são usadas para calcular os elementos da matriz de separação \mathbf{W} da expressão (3.5). Elas são funções usadas para aproximar e facilitar o cálculo da negentropia, visando à maximização da não-gaussianidade dos sinais fonte.

Para encontrar as funções custos é preciso fazer uso dos conceitos de maximização da entropia. Para maximizar a entropia, $H(x)$ é necessário satisfazer as restrições dadas em (3.8), onde $f_x(x)$ é a função densidade de probabilidade da variável x [4, 18].

$$\begin{aligned} f_x(x) &\geq 0, \\ \int_S f_x(x) dx &= 1, \\ \int_S f_x(x) G_i(x) dx &= c_i, \text{ para } i = 1, \dots, n \end{aligned} \quad (3.8)$$

em que S é o suporte de x , cujas fdp's $f_x(x) > 0$ e $G_i(x)$ é uma função não polinomial.

Um resultado muito importante da teoria da informação mostra que as fdp's que satisfazem as condições (3.8) têm a forma descrita em (3.9),

$$f_x(x) = A e^{\sum_{i=1}^n a_i G_i(x)}. \quad (3.9)$$

Em que A e a_i são constantes, de tal forma que $f_x(x)$ satisfaz as restrições impostas nas expressões (3.8).

A escolha das funções não polinomiais $G_i(x)$ deve ser feita de acordo com três critérios:

- 1 – A estimativa de $G_i(x)$ não deve ser estatisticamente difícil, em particular ela não deve ser muito sensível a “outliers”.
- 2 – O método da entropia máxima assume que a função $f_x(x)$, em (3.8), é integrável [8]. Portanto, para assegurar que a distribuição máxima da entropia exista, em primeiro lugar, a função $G_i(x)$ não deve crescer mais rapidamente do que quadraticamente em função do $|x|$, pois uma função de crescimento mais rápido pode conduzir a não integração de $f_x(x)$.
- 3 – A função $G_i(x)$ deve considerar aspectos importantes da distribuição de x , os quais são relevantes à determinação da entropia. Em particular, se a densidade $f_x(x)$, for conhecida, a função G_i ótima ideal, seria claramente – $\log(f_x(x))$, pois o $-E\{\log(f_x(x))\}$ fornece a entropia diretamente. Assim, pode-se usar para $G_i(x)$ as densidades logarítmicas de algumas densidades importantes conhecidas [4].

Os dois primeiros critérios são satisfeitos se $G_i(x)$ são funções que não crescem muito rápido à medida que aumenta $|x|$. Isso exclui, por exemplo, o uso de polinômios de ordem superior a 2, que são utilizados nas expansões de Gram-Charlier e Edgeworth [4]. Pode-se, então, buscar, de acordo com o critério 3, algumas distribuições bem conhecidas que também cumpram as duas primeiras condições.

O método da máxima entropia é usado no ICA por ser mais robusto que as aproximações convencionais. Um caso simples para essa aproximação é representado em (3.10) [4].

$$J(y) \approx k[E\{G(y_i)\} - E\{G(\nu)\}]^2. \quad (3.10)$$

Em que G é praticamente qualquer função não quadrática; k é uma constante irrelevante, em geral igual a 1; ν é uma variável aleatória gaussiana de média nula e variância unitária. Essa aproximação para a negentropia permite definir uma nova função custo para o problema do ICA. Para encontrar uma componente independente, na qual $\mathbf{y}_i = \mathbf{w}_i^T \mathbf{x}$, deve-se maximizar a função J , dada pela expressão (3.10), em que \mathbf{w} é o vetor peso sujeito à $E\{(\mathbf{w}^T \mathbf{x})^2\} = 1$.

Exemplos práticos de opções de G que são consistentes com os três critérios, acima, são os seguintes:

- Para medir a assimetria, pode-se usar, por razões heurísticas, a função:

$$G(x) = xe^{-x^2/2}, \quad (3.11)$$

que é suave e firme contra os “outliers”.

- As funções (3.12) – (3.13) são opções de G_i muito úteis [4, 25]:

$$G_1(y) = \frac{1}{a_1} \log(\cosh(a_1 y)), \quad (3.12)$$

$$G_2(y) = -e^{-y^2/2}. \quad (3.13)$$

Em que $1 \leq a_1 \leq 2$ é uma constante adequada, muitas vezes considerada igual a 1. Alternativamente, pode-se usar a função de quarta ordem que corresponde à aproximação pela curtose. Porém seu uso é justificado apenas para estimar componentes independentes sub-gaussianas, quando não há “outliers” [59].

$$G_3(y) = y^4/4. \quad (3.14)$$

As funções (3.12) – (3.14) são ilustradas na Figura 4. Para permitir a clareza na visualização das três funções, na mesma figura, restringiu-se o intervalo da ordena para $[-1,5, 1,5]$. Isso é necessário, pois os valores das funções G_1 e G_2 são bem menores do que os da função G_3 .

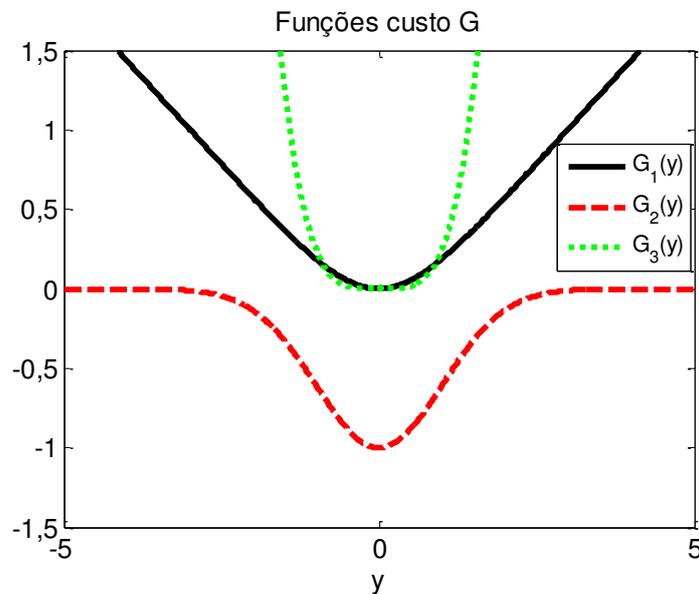


Figura 5 – Gráfico das funções G .

Nos algoritmos, que executam o ICA, são usadas funções g que são as derivadas das funções (3.12) – (3.14), elas resultam em aproximações muito precisas da negentropia. São elas:

$$g_1(y) = \text{tgh}(a_1 y), \quad (3.15)$$

$$g_2(y) = ye^{-y/2}, \quad (3.16)$$

$$g_3(y) = y^3. \quad (3.17)$$

Em que $1 \leq a_1 \leq 2$ é uma constante adequada, na maioria das vezes tomada como igual a 1. Os gráficos das funções (3.15) – (3.17) são mostrados na Figura 6. O mesmo artifício usado na Figura 5 foi usado na Figura 6 para permitir a clareza na visualização das três funções na mesma figura.

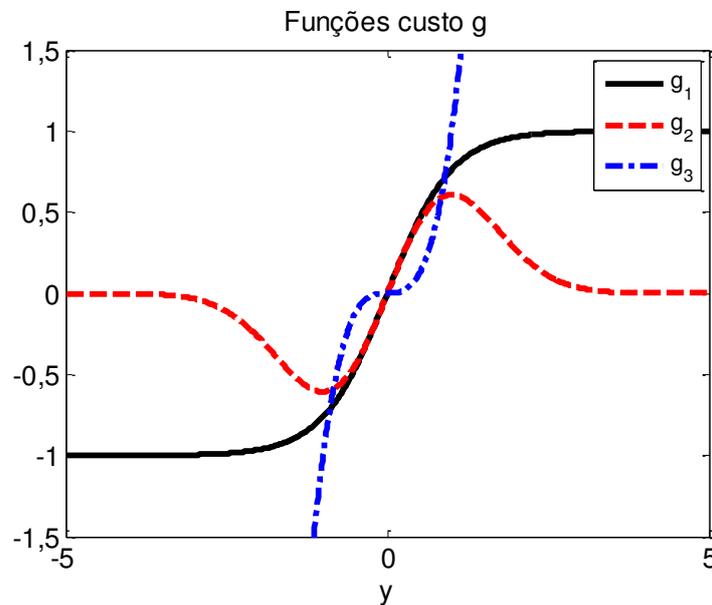


Figura 6 – Gráfico das funções g .

Nos algoritmos de ponto fixo, como é o caso do algoritmo FastICA [4], é usado à expressão de iteração (3.18), seguida de normalização.

$$\mathbf{w} \leftarrow E\{\mathbf{z}g(\mathbf{w}^T \mathbf{z})\} - E\{g'(\mathbf{w}^T \mathbf{z})\}\mathbf{w}. \quad (3.18)$$

Como se vê, em (3.18), são necessárias as derivadas das funções (3.15) – (3.17), ou seja, g' que são as derivadas de segunda ordem das funções (3.12) – (3.14). Essas derivadas são apresentadas a seguir.

$$g'_1(y) = a_1(1 - \operatorname{tgh}^2(a_1y)), \quad (3.19)$$

$$g'_2(y) = (1 - y^2)e^{-y^2/2}, \quad (3.20)$$

$$g'_3(y) = 3y^2. \quad (3.21)$$

Para definir qual a função g é mais adequada para maximizar a negentropia, ou seja, qual função g produzirá uma melhor estimativa dos sinais originais, é preciso ter informações sobre a fdp dos sinais fontes. Porém, como obtê-las quando não se conhece a fdp das fontes? Uma das soluções para esse problema está na construção dos histogramas dos sinais e na aproximação destes por funções de distribuição já conhecidas, como: gaussiana, uniforme, exponencial, gama, log-normal, etc. Nesse sentido foi desenvolvido um programa em *Matlab*[®], para gerar os histogramas dos sinais envolvidos neste estudo (ver anexo A).

Para a fdp corresponder ao seu histograma tem-se que somar todos os valores da variável aleatória e dividi-los pela frequência relativa, que nada mais é que dividir a soma pelo número de amostras da variável aleatória [56].

Na validação do programa foram testadas algumas das distribuições conhecidas na literatura. Exemplos são mostrados na Tabela 1.

Pode-se verificar pelos valores mostrados nos gráficos apresentados na Tabela 1, que o programa desenvolvido funciona bem e pode ser usado para inferir a fdp de sinais aleatórios quaisquer e ajudar na escolha da função custo g mais adequada. As funções custo (ou funções objetivo) são usadas no algoritmo FastICA (descrito na Seção 4.1).

3.4 Conclusão do Capítulo

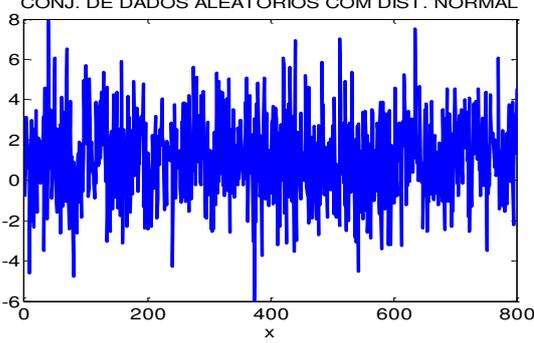
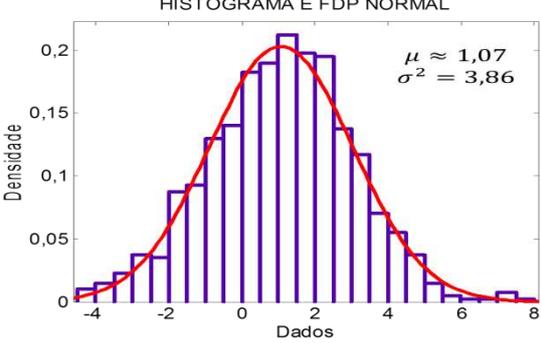
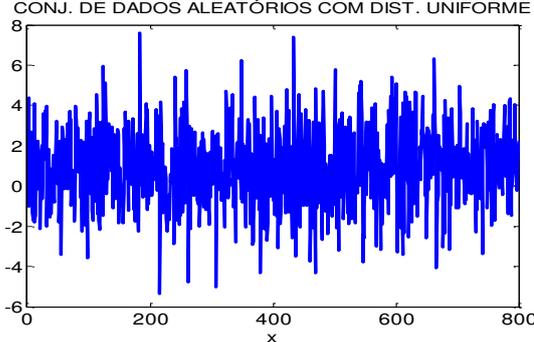
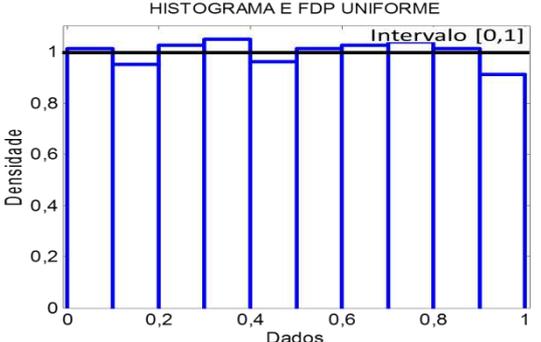
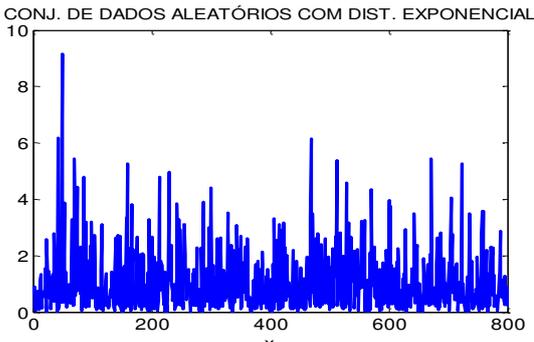
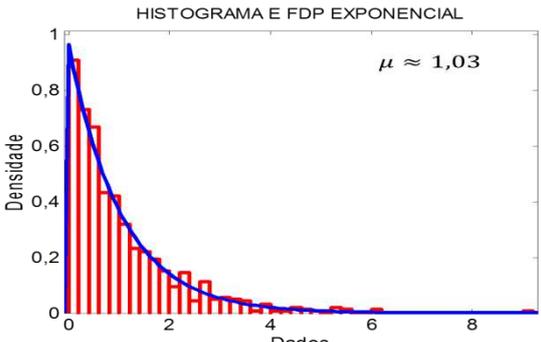
Neste Capítulo tratou-se da definição e embasamento matemático envolvido na análise da componente independente, juntamente com a descrição matemática do modelo ICA usado neste trabalho. Também foram apresentadas e discutidas as funções objetivo (funções custo) usadas nos algoritmos que implementam o ICA. Mostraram-se as três funções que são usadas como aproximação para resolver o problema de separação cega de

fontes usando o ICA. Essas devem obedecer a três critérios e foram descritas as variáveis envolvidas no modelo do ICA.

Foi desenvolvida uma rotina, em *Matlab*[®], para auxiliar na construção de histogramas, que são usados para determinar a fdp aproximada de uma variável aleatória. A partir da fdp é possível escolher qual é a função custo mais adequada para ser usada na maximização da negentropia.

No caso prático, o vetor de medidas aleatórias \mathbf{x} deve ser preenchido pelos valores obtidos em medição, é sobre esses valores que se aplica o ICA para a estimação das fontes originais.

Tabela 1 - Histogramas das fdp's conhecidas.

Dados aleatórios	Histogramas e aproximação da fdp
<p>CONJ. DE DADOS ALEATÓRIOS COM DIST. NORMAL</p> 	<p>HISTOGRAMA E FDP NORMAL</p> 
<p>CONJ. DE DADOS ALEATÓRIOS COM DIST. UNIFORME</p> 	<p>HISTOGRAMA E FDP UNIFORME</p> 
<p>CONJ. DE DADOS ALEATÓRIOS COM DIST. EXPONENCIAL</p> 	<p>HISTOGRAMA E FDP EXPONENCIAL</p> 

Capítulo 4

4. Simulações Usando o ICA

Neste Capítulo é tratado a implementação numérica do método de análise da componente independente usando o algoritmo FastICA, feita uma avaliação do método em termos de sinais fontes simulados e a análise das funções custo usadas para maximizar a não-gaussianidade dos sinais fontes tratadas na Seção 3.3.

Na Seção 4.1 é descrito o algoritmo FastICA e suas características, destacando a escolha da ortogonalização simétrica como forma de encontrar a matriz \mathbf{W} . A Seção 4.2 traz uma avaliação do FastICA por meio de simulações utilizando o coeficiente de correlação como parâmetro de avaliação. Na Seção 4.3 é feito um estudo das funções custo, visando escolher qual a mais adequada para a aplicação do ICA. Na Seção 4.4 é feita uma análise do desempenho do ICA para o caso específico de fontes senoidais com fases conhecidas. Na Seção 4.5 são apresentadas as conclusões do capítulo.

4.1 Programação do Algoritmo FastICA

O Algoritmo FastICA é um algoritmo de ponto fixo idealizado por Hyvärinen e Oja, em 1997 [35]. Ele se baseia na maximização, ou minimização, de uma função custo (ou objetivo), e fornece os pontos em que o gradiente da função custo se anula. O FastICA foi desenvolvido com o intuito de ser mais rápido computacionalmente que outros algoritmos como: TFBSS (*Time-Frequency Blind Source Separation*), SOBIUM (*Second-Order Blind Identification of Under-determined Mixtures*) e outros algoritmos de segunda ordem; JADE (*Joint Approximate Diagonalization of Eigenmatrices*), FOBIUM (*Fourth-Order Blind Identification of Under-determined Mixtures*), STOTD (*Simultaneous Third-Order Tensor Diagonalization*) e outros algoritmos de ordem superior [25]; algoritmos baseados na maximização da verossimilhança

(ML – *Maximum likelihood*), além do algoritmo do gradiente ascendente de *Bell-Sejnowski* (BS) e o algoritmo do gradiente natural ACY (*Amari, Cichocki and Yahg*) [4].

O FastICA foi escolhido, por nós, por ser computacionalmente mais rápido e de simples implementação; por não necessitar de um número elevado de amostras; apresentar melhor desempenho do que outros algoritmos iterativos como InfoMax (*Information Maximization*) e PICA (*Pearson Independent Component Analysis*), para situações com pequena e elevada relação sinal ruído (SNR) (desde – 5 dB até 25 dB); ser aplicável ao caso sobre estimado (mais medições do que fontes) [25]; ter um critério de separação mais forte (a independência) do que algoritmos que usam apenas a decorrelação (a exemplo do SOBI (*Second-Order Blind Identification*), SOBIUM e PCA (*Principal Component Analysis*)) e; ao contrário dos algoritmos baseados em gradiente, não existe taxa de aprendizagem ou de outros parâmetros ajustáveis no algoritmo, que faz com que ele seja fácil de usar e mais viável. Por ser um algoritmo de ponto fixo a sua convergência é demonstrada ser cúbica [60, 61].

O FastICA usa a negentropia ou a curtose como parâmetro de maximização da não-gaussianidade dos sinais fontes; e duas opções de cálculo da matriz de separação \mathbf{W} : por deflação ou por ortogonalização simétrica para cada iteração do algoritmo.

A determinação dos elementos da matriz \mathbf{W} por deflação propaga o erro de estimativa de um elemento (\mathbf{w}_i) para outro elemento da matriz \mathbf{W} , já que cada \mathbf{w}_i é calculado um após o outro e depende do elemento anteriormente calculado (\mathbf{w}_{i-1}) [4]. Além disso, ela apresenta uma complexidade computacional muito maior que a ortogonalização simétrica quando se aumenta o número de fontes [25]. Por isso, optou-se pela ortogonalização simétrica.

A ortogonalização simétrica é usada para evitar que um vetor seja “privilegiado” em relação a outros. Isso implica que os vetores \mathbf{w}_i não são estimados um por um, eles são estimados em paralelo. Com isso evita-se o problema da ortogonalização por deflação.

A versão do algoritmo para maximização da negentropia, considerando-se a recuperação simultânea de todas as fontes presentes na mistura (ortogonalização simétrica), pode ser vista abaixo [35].

1 – Pré-processamento dos dados: centralizar os dados a fim de tornar a média nula.

2 – Fazer o branqueamento dos dados. Os dados resultantes formam um vetor denominado de \mathbf{z} ; o vetor \mathbf{z} é dito branco, isto é, suas componentes são descorrelacionadas e sua variância é igual à unidade, ou seja, a matriz de covariância de \mathbf{z} é igual à matriz identidade;

3 – Inicializar com vetores \mathbf{w}_i aleatoriamente, mantendo a norma unitária;

4 – Para todo $i = 1, 2, \dots, N$, maximizar a negentropia da saída $y_i = \mathbf{w}_i^T \mathbf{z}$,

$$\mathbf{w}_i \leftarrow E\{\mathbf{z}g(\mathbf{w}_i^T \mathbf{z})\} - E\{g'(\mathbf{w}_i^T \mathbf{z})\}\mathbf{w}_i. \quad (4.1)$$

5 – Organizar os vetores \mathbf{w}_i em uma matriz $\mathbf{W} = (\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N)^T$, e realizar o processo de ortogonalização simétrica:

$$\mathbf{W} \leftarrow (\mathbf{W} \times \mathbf{W}^T)^{-1/2} \cdot \mathbf{W}. \quad (4.2)$$

6 – Se o algoritmo não convergir retornar para o passo 4. A convergência significa que os valores novos e antigos de \mathbf{w} apontam na mesma direção, ou seja, o valor absoluto do seu produto escalar é (quase) igual a 1 [4, 59]. Não é necessário que o vector convirja para um único ponto, uma vez que \mathbf{w} e $-\mathbf{w}$ definem a mesma direção.

O pré-processamento, ou seja, o branqueamento (ou descorrelação) é usado para acelerar o algoritmo. Ele é fundamentalmente uma transformação, a qual restringe a estimativa ao espaço de matrizes ortogonais. De uma forma geral, um sinal é dito ser branco se a sua densidade espectral de potência for constante.

Se duas variáveis aleatórias são descorrelacionadas e têm variâncias iguais a 1, então elas são chamadas de variáveis aleatórias brancas. Isso implica que a matriz de covariância é igual à identidade [4],

$$E\{\mathbf{z} \cdot \mathbf{z}^T\} = \mathbf{I}. \quad (4.3)$$

Matematicamente o branqueamento é a transformação linear:

$$\mathbf{z} = \mathbf{V} \cdot \mathbf{x}. \quad (4.4)$$

Ou seja, o branqueamento da variável aleatória \mathbf{x} é feito por uma matriz \mathbf{V} tal que $\mathbf{V} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T$, onde a matriz \mathbf{E} é ortogonal, com colunas que correspondem aos autovetores de $E\{\mathbf{x} \cdot \mathbf{x}^T\}$ (matriz de correlação da variável aleatória \mathbf{x}), e \mathbf{D} é uma matriz diagonal contendo os autovalores de $E\{\mathbf{x} \cdot \mathbf{x}^T\}$ ($\mathbf{D} = \text{diag}(d_1, d_2, \dots, d_n)$):

$$E\{\mathbf{x} \cdot \mathbf{x}^T\} = \mathbf{E} \cdot \mathbf{D} \cdot \mathbf{E}^T. \quad (4.5)$$

A operação de branqueamento transforma a matriz \mathbf{A} , do modelo do ICA (expressão 3.1), em uma nova matriz $\bar{\mathbf{A}}$. Logo,

$$\mathbf{z} = \mathbf{V} \cdot \mathbf{A} \cdot \mathbf{s} = \bar{\mathbf{A}} \cdot \mathbf{s}. \quad (4.6)$$

Considere uma transformação ortogonal de \mathbf{z} , por meio da matriz \mathbf{U} :

$$\mathbf{y} = \mathbf{U} \cdot \mathbf{z}. \quad (4.7)$$

Devido à ortogonalidade de \mathbf{U} , tem-se que:

$$E\{\mathbf{y} \cdot \mathbf{y}^T\} = E\{\mathbf{U} \cdot \mathbf{z} \cdot \mathbf{z}^T \cdot \mathbf{U}^T\} = \mathbf{U} \cdot \mathbf{I} \cdot \mathbf{U}^T = \mathbf{I}, \quad (4.8)$$

ou seja, \mathbf{y} também é um vetor branco. O branqueamento fornece uma transformação ortogonal do vetor \mathbf{s} . Como:

$$E\{\mathbf{z} \cdot \mathbf{z}^T\} = \bar{\mathbf{A}} \cdot E\{\mathbf{s} \cdot \mathbf{s}^T\} \cdot \bar{\mathbf{A}}^T = \bar{\mathbf{A}} \cdot \bar{\mathbf{A}}^T = \mathbf{I}, \quad (4.9)$$

pode-se concluir que a matriz de mistura que se deseja determinar é ortogonal. Isto implica que ao invés de se estimar n^2 parâmetros da matriz \mathbf{A} , é necessário estimar uma matriz de misturas ortogonal $\bar{\mathbf{A}}$, que contém apenas $n \cdot (n - 1)/2$ graus de liberdade.

Como visto anteriormente, o algoritmo FastICA não requer passo de adaptação e, portanto, não é necessário inserir nenhum outro parâmetro para a separação. Sendo assim, é suficiente fornecer somente os vetores das misturas para que sejam estimadas as fontes.

Uma versão do algoritmo FastICA foi programada no *Matlab*[®] para entendimento das etapas do algoritmo. Em seguida ela foi comparada com outra versão disponível em [4] (ver anexo A) e os resultados foram

satisfatórios, ou seja, para as mesmas condições os resultados obtidos na versão programada por nós foram iguais aos apresentados pela versão em [4]. Como a versão programada por [4] é mais flexível, apresenta a possibilidade de simulação de mais fontes, possui uma interface fácil, permite as duas ortogonalizações (simétrica e deflacionária), passou-se a usá-la. A essa versão foi adicionando o cálculo do coeficiente de correlação.

4.2 Avaliação do FastICA

Para avaliar o algoritmo FastICA e verificar as potencialidades e limitações do método ICA, foram realizadas diversas simulações usando fontes de sinais conhecidos e verificada o quanto as componentes independentes (sinais estimados) se assemelham aos sinais fontes originais.

Para comparar o quanto os sinais estimados são próximos dos sinais originais usou-se o parâmetro estatístico chamado de coeficiente de correlação de Pearson [62]. Ele expressa uma medida quantitativa do grau de dependência linear entre duas variáveis aleatórias. Esse coeficiente varia entre os valores -1 e 1 . O valor 0 (zero) significa que não há relação linear entre as variáveis aleatórias. O valor 1 indica uma relação linear perfeita e o valor -1 uma relação linear perfeita, porém inversa, ou seja, quando uma das variáveis aumenta a outra diminui. Quanto mais próximo estiver de 1 ou -1 , mais forte é a associação linear entre as duas variáveis. Isso indica o grau de semelhança entre duas variáveis. O coeficiente de correlação para duas séries de sinais no tempo y_i e s_j podem ser calculados por (4.10), onde \bar{y} e \bar{s} representam os valores médio de y_i e s_j , respectivamente [6].

$$Coefcorr_{ij}(y_i, s_j) = \frac{\sum_{t=1}^N (y_i(t) - \bar{y})(s_j(t) - \bar{s})}{\sqrt{\sum_{t=1}^N (y_i(t) - \bar{y})^2 \times \sum_{t=1}^N (s_j(t) - \bar{s})^2}}. \quad (4.10)$$

As correlações não dependem da escala de valores de y ou s . Por exemplo, obtém-se o mesmo valor de *Coefcorr* se for medido altura e peso em metros e quilogramas ou em pés e libras. A interpretação qualitativa do valor do *Coefcorr* depende muito de cada contexto em particular. Em [62] o coeficiente de correlação é avaliado da seguinte forma:

- Se $0,0 < |Coefcorr| < 0,3$, existe correlação linear fraca;
- Se $0,3 \leq |Coefcorr| < 0,6$, existe correlação linear moderada;
- Se $0,6 \leq |Coefcorr| < 0,9$, existe correlação linear forte;
- Se $0,9 \leq |Coefcorr| < 1,0$, existe correlação linear muito forte.

Nas simulações iniciais foram usados como fontes originais senoides e sinais aleatórios, com valores entre 1 e -1 e com mesma probabilidade.

As misturas dos sinais fontes são feitas de forma aleatória usando uma matriz gerada pelo comando “rand”, no *Matlab*[®]. Nas figuras que se seguem a unidade do eixo x é o número de amostras, até que se especifique outra unidade e no eixo y a amplitude está normalizada.

Na Figura 7 são apresentados os resultados para os sinais fontes seno e cosseno, para os sinais misturados e estimados pelo ICA, respectivamente. Como podem ser observados, na Figura 7, os sinais estimados pelo ICA são idênticos aos sinais originais, exceto a inversão de fase do seno e a diferença de amplitude entre os sinais originais e os sinais estimados.

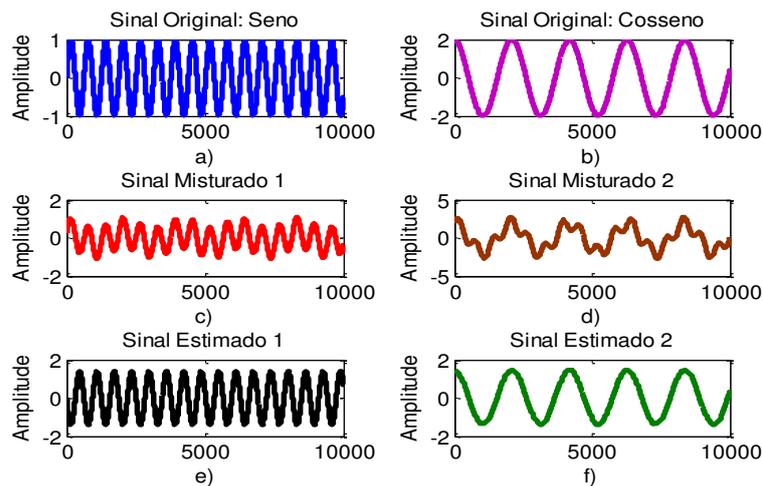


Figura 7 – a) e b) Sinais fontes: seno e cosseno; c) e d) Sinais misturados; e) e f) Sinais estimados após aplicar o ICA.

A simulação dos sinais fontes como sendo sinais aleatórios com valores entre 1 e -1 , com mesma probabilidade, são apresentadas na Figura 8.

No resultado visto na Figura 8 percebe-se claramente a inversão de fase nos dois sinais originais (sinais fontes), característica marcante do ICA.

Nas simulações se percebe que o ICA, não garante que os sinais estimados tenham a mesma amplitude, mesma fase e apareçam na mesma

ordem que os sinais originais, como era de se esperar. Porém, ele conseguiu separar todas as fontes usadas nas simulações.

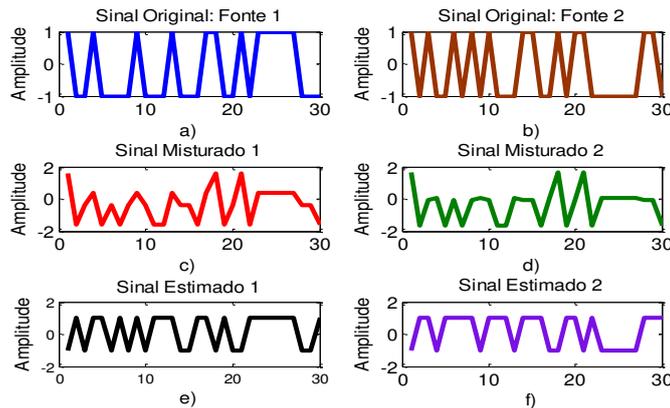


Figura 8 – a) e b) Sinais fontes aleatórios (amplitude entre -1 e 1); c) e d) Sinais misturados; e) e f) Sinais estimados após aplicar o ICA.

4.3 Avaliação das Funções Custo

Para obter um melhor resultado na aplicação do ICA é necessário conhecer a fdp dos sinais fontes e assim escolher uma das funções custo (expressões 3.15 – 3.17) que mais se aproxime da distribuição. Uma vez que não se sabe como é a distribuição dos sinais fontes a pergunta que surge é: qual seria a função custo mais adequada para começar uma avaliação? Visando responder essa questão foram realizadas simulações com sinais senoidais, dente de serra, tangente e ruído aleatório, obtidos de [63]. Nessa avaliação foram feitas comparações da mistura e separação desses sinais dois a dois e foram considerados bons resultados quando o coeficiente de correlação (*Coefcorr*) foi maior ou igual a 0,98. Na Figura 9, são apresentados os sinais fontes que foram utilizados na avaliação das funções custo usadas no FastICA.

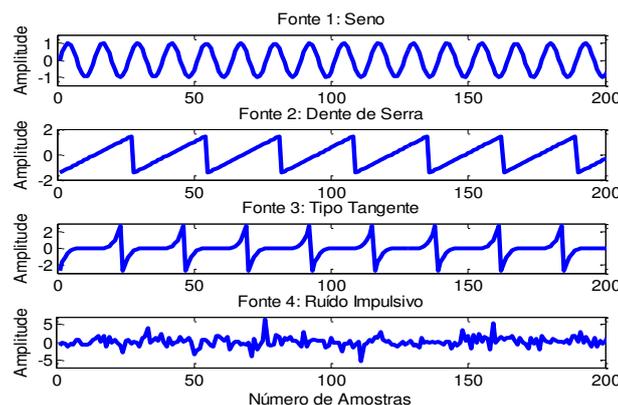


Figura 9 – Sinais fontes: seno, dente de serra, tangente e ruído impulsivo, respectivamente.

Repetiu-se cada simulação 50 vezes, totalizando 300 simulações combinando duas a duas as fontes originais: seno e tangente; seno e dente de serra; seno e ruído impulsivo; tangente e dente de serra; tangente e ruído impulsivo e; dente de serra e ruído impulsivo. Para cada uma das simulações foram aplicadas as três funções custo e calculado o coeficiente de correção. O resultado foi classificado em houve ou não houve separação dos sinais na mesma ordem em que eles foram inseridos no ICA. Se o sinal fonte s_1 é o seno e o sinal fonte s_2 é o ruído impulsivo, o seno naturalmente deveria ser recuperado no gráfico do sinal estimado 1 (y_1) e o ruído impulsivo no gráfico do sinal estimado 2 (y_2), e assim por diante. Aqui serão mostradas apenas as mesmas combinações: seno e o ruído impulsivo; dente de serra e o ruído impulsivo. As observações para essas combinações foram verificadas nas demais.

A avaliação das fontes (sinais originais) sendo estas: um sinal senoidal e ruído impulsivo são apresentados na primeira linha da Figura 10; na segunda linha, têm-se o resultado da mistura desses sinais e na terceira linha as componentes independentes estimadas após o ICA.

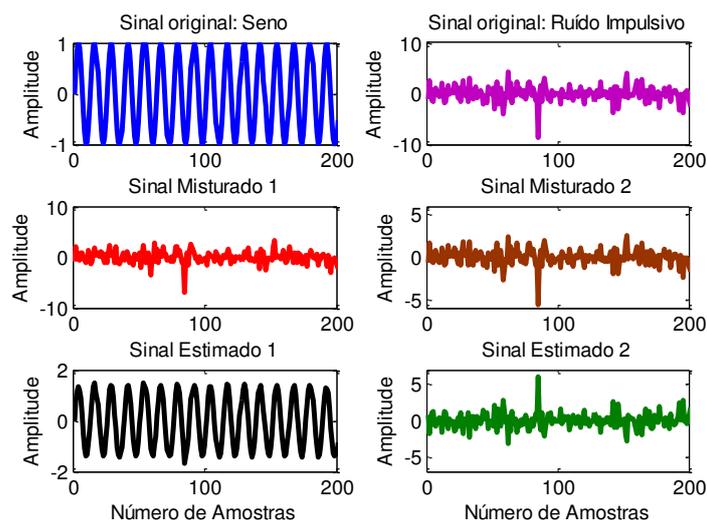


Figura 10 – Sinais originais: seno e ruído impulsivo, sinais misturados e estimados pelo ICA, respectivamente.

Na Tabela 2 são apresentados os resultados para cada função custo, aplicada à separação dos sinais seno e ruído impulsivo. A simulação foi

repedida 50 vezes e calculado o coeficiente de correlação entre os sinais estimados pelo ICA e os sinais originais.

Tabela 2 - Avaliação das funções custo para os sinais fontes seno e ruído impulsivo.

Função custo (g)	Sinal original	Coeficiente de correlação (em 50 repetições)
$g_1 = tgh(a_1y)$	Senoide	Em 35 repetições $CoefCorr = 0,9894$
		Em 15 repetições $CoefCorr = 0,0359$
	Ruído impulsivo	Em 35 repetições $CoefCorr = 0,9890$
		Em 15 repetições $CoefCorr = 0,0289$
$g_2 = ye^{-y^2/2}$	Senoide	Em 40 repetições $CoefCorr = 0,9985$
		Em 10 repetições $CoefCorr = 0,0471$
	Ruído impulsivo	Em 40 repetições $CoefCorr = 0,9983$
		Em 10 repetições $CoefCorr = 0,0760$
$g_3 = y^3$	Senoide	Em 40 repetições $CoefCorr = 0,9994$
		Em 10 repetições $CoefCorr = 0,0412$
	Ruído impulsivo	Em 40 repetições $CoefCorr = 0,9994$
		Em 10 repetições $CoefCorr = 0,0426$

Analisando os valores dos coeficientes de correlação da Tabela 2, conclui-se que a função $g_3 = y^3$ é mais apropriada que a função $g_2 = ye^{-y^2/2}$ para separar esses tipos de sinais, na mesma ordem em 40 repetições. Por exemplo, utilizando a função g_3 obtêm-se os valores para o coeficiente de correlação: $CoefCorr$ (senoide) = 0,9994 e $CoefCorr$ (ruído impulsivo) = 0,9994, enquanto que usando a função g_2 obtêm-se os valores: $CoefCorr$ (senoide) = 0,9985 e $CoefCorr$ (ruído impulsivo) = 0,9983. Observe que a função $g_1 = tgh(a_1y)$ é a menos adequada para separar os sinais senoidais e o ruído impulsivo, na mesma ordem, que as outras funções (valores dos coeficientes de correlação: $CoefCorr$ (senoide) = 0,9894 e $CoefCorr$ (ruído impulsivo) = 0,9890, em apenas 35 repetições).

As simulações para os sinais dente de serra e ruído impulsivo são ilustradas na Figura 11, juntamente com a mistura resultante e os sinais estimados.

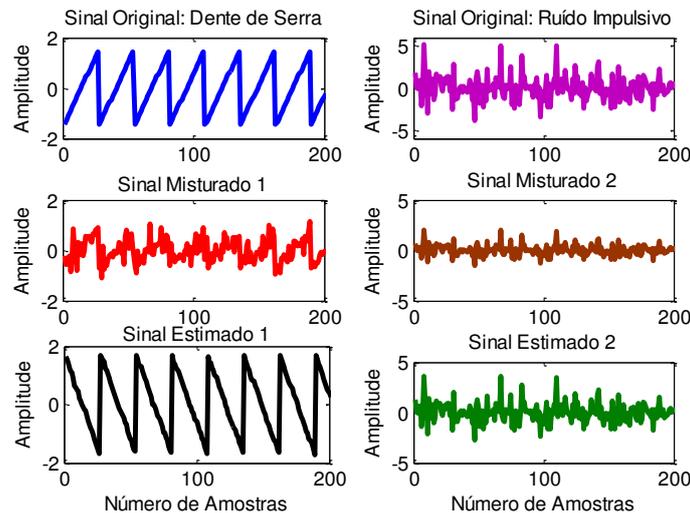


Figura 11 – Sinais originais: dente de serra e ruído impulsivo, sinais misturados e estimados pelo ICA, respectivamente.

Na Tabela 3 são apresentados os resultados para cada função custo aplicados à separação dos sinais dente de serra e o ruído impulsivo.

Tabela 3 - Avaliação das funções custo para os sinais fontes dente de serra e ruído impulsivo.

Função custo (g)	Sinal original	Coefficiente de correlação (em 50 repetições)
$g_1 = tgh(a_1y)$	Dente de serra	Em 40 repetições $CoefCorr = 0,9945$
		Em 10 repetições $CoefCorr = 0,0982$
	Ruído impulsivo	Em 40 repetições $CoefCorr = 0,9951$
		Em 10 repetições $CoefCorr = 0,1097$
$g_2 = ye^{-y^2/2}$	Dente de serra	Em 35 repetições $CoefCorr = 0,9972$
		Em 15 repetições $CoefCorr = 0,0429$
	Ruído impulsivo	Em 35 repetições $CoefCorr = 0,9971$
		Em 15 repetições $CoefCorr = 0,0500$
$g_3 = y^3$	Dente de serra	Em 45 repetições $CoefCorr = 0,9954$
		Em 5 repetições $CoefCorr = 0,0112$
	Ruído impulsivo	Em 45 repetições $CoefCorr = 0,9953$
		Em 5 repetições $CoefCorr = 0,0010$

Observando os valores dos coeficientes de correlação da Tabela 3, vê-se que a função $g_3 = y^3$ é mais recomendada que a função $g_1 = tgh(a_1y)$ para separar os sinais usados nessa tabela, pois apresenta maiores valores para o coeficiente de correlação num maior número de repetições (45 repetições). Por exemplo, usando a função g_3 obtêm-se os valores: $CoefCorr$

(dente de serra) = 0,9954 e $CoefCorr$ (ruído impulsivo) = 0,9953, enquanto que usando a função g_1 obtêm-se os valores: $CoefCorr$ (dente de serra) = 0,9845 e $CoefCorr$ (ruído impulsivo) = 0,9951. Observa-se ainda, que a função $g_2 = ye^{-y^2/2}$ é a menos indicada para separá-los, pois apresenta menos acertos na separação (apenas em 35 repetições), apesar de elevados valores para os coeficientes de correlação ($CoefCorr$ (dente de serra) = 0,9994 e $CoefCorr$ (ruído impulsivo) = 0,9994).

O algoritmo FastICA com a função custo $g_3 = y^3$, apresentou maiores valores de correlação nos casos trabalhados. Portanto, ela deve ser a primeira função custo a ser considerada para se buscar a separação dos sinais fontes a partir das misturas (sinais observados). É importante ressaltar que em nenhum dos experimentos o ICA deixou de recuperar as fontes originais usando as funções custo g_1 e g_2 .

Os testes acima demonstram que o ICA tem aplicabilidade para vários tipos de sinais e que não garante que os sinais estimados terão mesma amplitude e fase dos sinais originais, mas que terão o mesmo comportamento e podem ser reconhecidos mesmo misturados a outros sinais.

4.4 Avaliação do ICA para Sinais Senoidais com Fases Determinadas

Nas simulações apresentadas na Seção 4.3 foram testadas misturas de sinais diferentes. Nesta Seção é testada a mistura de sinais senoidais com mesma frequência, mesma amplitude e diferenciando-se apenas na fase. O objetivo é verificar se o ICA é capaz de recuperar esses sinais mesmo que eles tenham pouquíssima diferença de fase ($\Delta\theta = 1^\circ$, por exemplo). Todas as simulações foram feitas para a frequência de 1,8 GHz, escolhida em função de existirem, no laboratório, antenas que operam nessa frequência.

Da mesma forma que na Seção 4.3, os sinais fontes foram misturados por uma matriz aleatória que tem a função de simular as misturas dos sinais. Esta mistura acontece na prática durante o processo de medição. Foi usado o FastICA com a função custo g_3 e ortogonalização simétrica.

Na Figura 12, são apresentados os gráficos dos sinais senoidais com as fases 0° , 45° , 90° e 180° , respectivamente.

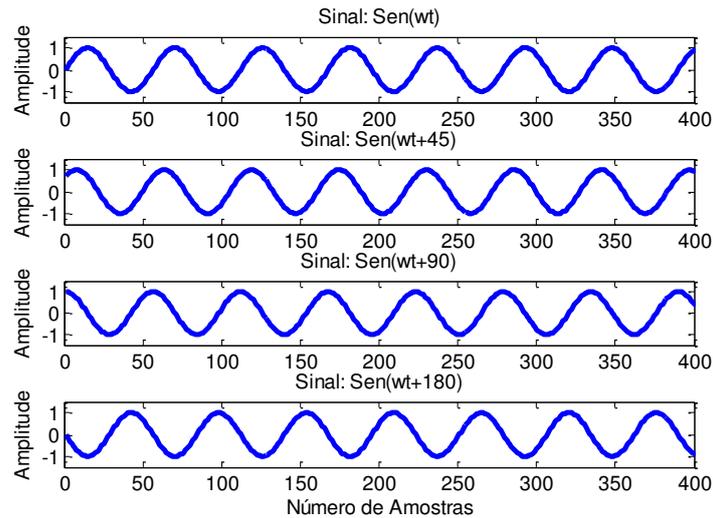


Figura 12 – Sinais senoidais de fases diferentes.

Os sinais da Figura 12 foram combinados dois a dois, misturados aleatoriamente e aplicados ao ICA. Os sinais estimados das fontes representados na Figura 13 foram obtidos dos sinais misturados: $s_1 = \text{sen}(\omega t)$ e $s_2 = \text{sen}(\omega t + 45)$.

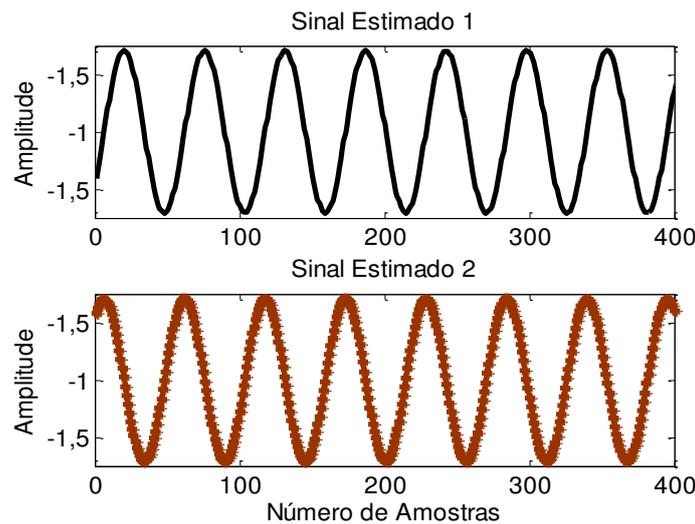


Figura 13 – Sinais estimados pelo ICA: $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 45)$.

Comparando os gráficos da Figura 13 com os gráficos da Figura 12 (duas primeiras linhas) vê-se que houve um deslocamento de fase, aproximadamente, $34,6^\circ$ na fase do sinal estimado 1 em relação ao sinal original ($\text{sen}(\omega t)$), mas isso não comprometeu a separação e identificação pelo

ICA. Assim, o sinal estimado 1 apresenta comportamento idêntico ao seno com fase 0° e o sinal estimado 2 ao seno com fase 45° .

Na Figura 14, têm-se os sinais estimados, após o processamento pelo ICA, para a mistura dos sinais: $s_1 = \text{sen}(\omega t)$ e $s_2 = \text{sen}(\omega t + 90)$.

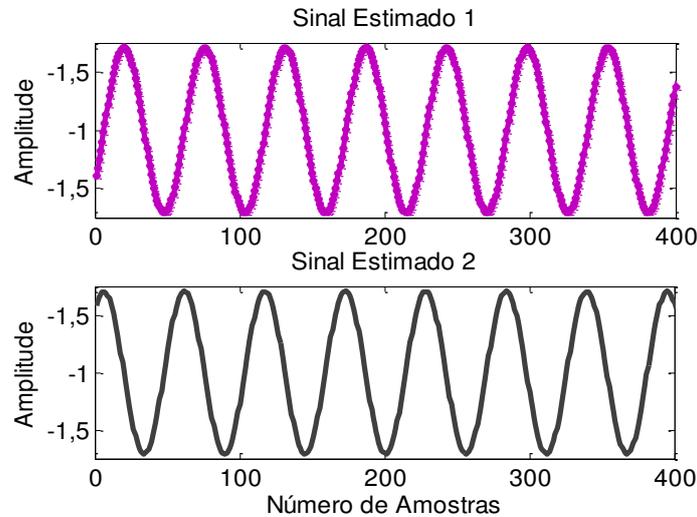


Figura 14 – Sinais estimados pelo ICA: $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 90)$.

Se comparando os gráficos da Figura 14 com os gráficos da Figura 12 (primeira e terceira linhas) percebe-se, também, um deslocamento na fase do sinal estimado 1 em relação ao sinal original ($\text{sen}(\omega t)$), de aproximadamente, $33,7^\circ$. Já entre o sinal estimado 2 e o sinal original $\text{sen}(\omega t + 90)$ ocorre um deslocamento de $38,6^\circ$.

Para o caso em que as fontes são $s_1 = \text{sen}(\omega t)$ e $s_2 = \text{sen}(\omega t + 180)$ o resultado obtido pelo ICA é mostrado na Figura 15.

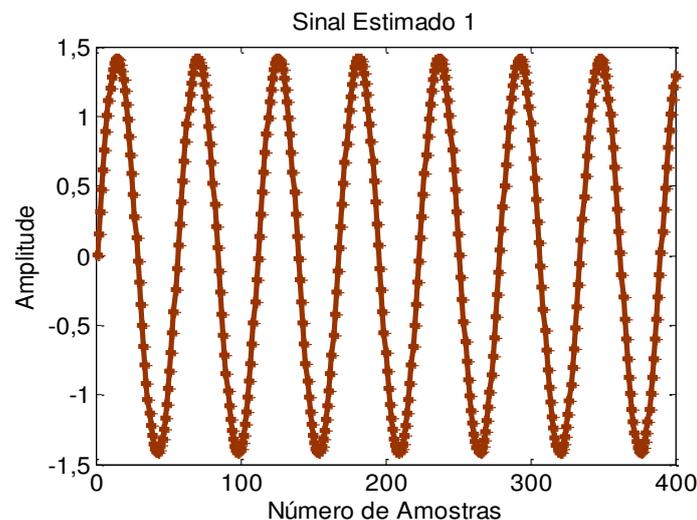


Figura 15 – Sinal estimado pelo ICA: $\text{sen}(\omega t)$ ou $\text{sen}(\omega t + 180)$.

O resultado visto na Figura 15 revela que o ICA não foi capaz de identificar e separar os sinais seno de fase 0° e seno de fase 180° , pois essa situação produz “indeterminações” no algoritmo do ICA, devido os sinais não serem estatisticamente independentes. No método ICA é necessário calcular a matriz de covariância entre os sinais (pré-processamento, ou seja, o branqueamento) que, nesse caso, possui um dos seus elementos zero, conseqüentemente, apenas um autovalor e um autovetor. Isso implica, portanto, na existência de apenas um sinal. Na etapa de branqueamento os dois sinais já não são apresentados. Não é possível concluir que o sinal estimado, na Figura 15, seja o seno de fase 0° ou o seno de fase 180° , uma vez que ICA pode inverter a fase dos sinais quando eles são estimados.

Outras combinações foram feitas e aplicadas ao ICA (não mostradas aqui), foram elas: $\text{sen}(\omega t + 45)$ e $\text{sen}(\omega t + 90)$; $\text{sen}(\omega t + 45)$ e $\text{sen}(\omega t + 180)$; $\text{sen}(\omega t + 90)$ e $\text{sen}(\omega t + 180)$. Em todos esses casos o ICA conseguiu estimar os sinais originais.

Dos testes acima, o ICA não conseguiu separar apenas os sinais $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 180)$. Nos casos em que o segundo sinal tinha fase diferente de 180° o ICA conseguiu separar, mas os sinais recuperados têm fases um pouco diferentes dos sinais originais, em geral, $\Delta\theta < 40^\circ$.

Os resultados obtidos até aqui motivaram testes com o ICA para sinais senoidais com fase 0° e 179° (ou 181°), respectivamente. Outro teste feito foi para dois sinais senoidais com pouca diferença de fase [64], por exemplo, um sinal com fase 0° e outro com fase 1° .

Na Figura 16.a é apresentado os sinais estimados para as fontes $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 179)$ e na Figura 16.b os sinais $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 1)$. Nos dois casos o ICA conseguiu identificar e separar os dois sinais, ainda que com fases diferentes dos sinais originais.

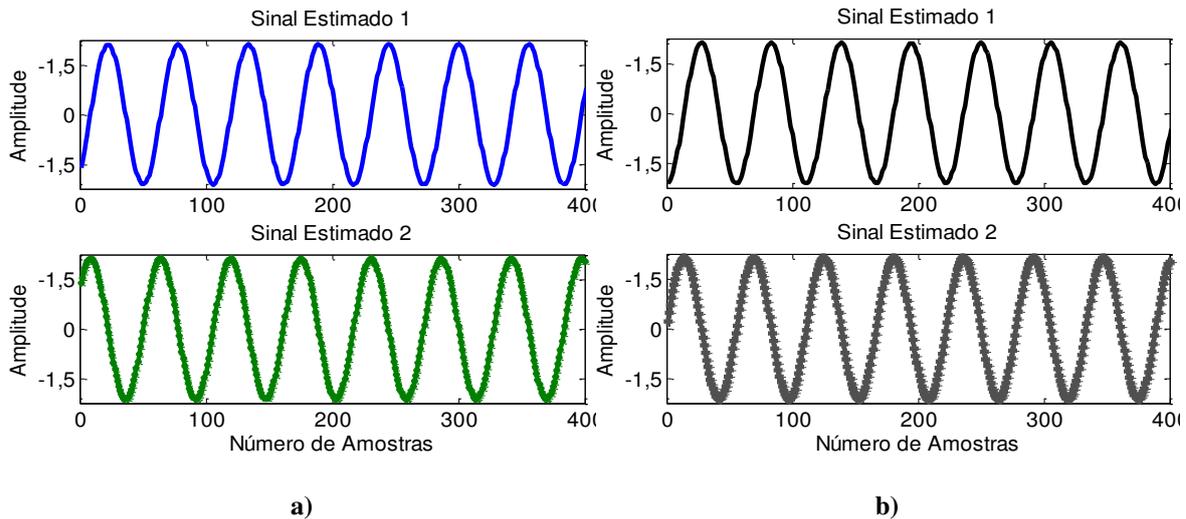


Figura 16 – Sinais estimados pelo ICA: a) $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 179)$; b) $\text{sen}(\omega t)$ e $\text{sen}(\omega t + 1)$.

Os casos analisados para sinais com pequenas diferenças de fase demonstram que o ICA consegue separar e identificar duas fontes, mesmo que estas sejam idênticas, embora essa estimativa seja comprometida pelo deslocamento da fase dos dois sinais estimados em relação aos sinais originais.

Para verificar o potencial do ICA para separar fontes, cujos dados de entrada se encontram no domínio da frequência, foram simulados, no domínio do tempo, dois sinais fontes: um AM (amplitude modulada) e outro FM (frequência modulada) [6], em seguida aplicou-se a transformada rápida de Fourier, para obter seus espectros de potência. Os espectros foram misturados aleatoriamente e passados para o método ICA. Os sinais AM e FM foram:

$$\text{Sinal AM: } s_1 = (1 + 0,8\text{sen}(2\pi f_{mod1}t)) \cdot \text{sen}(2\pi f_1t) \quad (4.11)$$

$$\text{Sinal FM: } s_2 = \cos(2\pi f_2t + 2\cos(2\pi f_{mod2}t)). \quad (4.12)$$

Em que f_1 (100 MHz) e f_2 (150 MHz) são as frequências das portadoras dos sinais AM e FM, respectivamente; f_{mod1} (10 MHz) e f_{mod2} (12 MHz) são as frequências de modulação dos sinais AM e FM, respectivamente.

Na Figura 17 são mostrados os gráficos dos sinais AM e FM nos domínios do tempo e da frequência, respectivamente. A mistura dos dados das curvas, da segunda coluna dessa figura, serviram de entrada para o algoritmo FastICA. Os sinais estimados podem ser vistos na Figura 18.

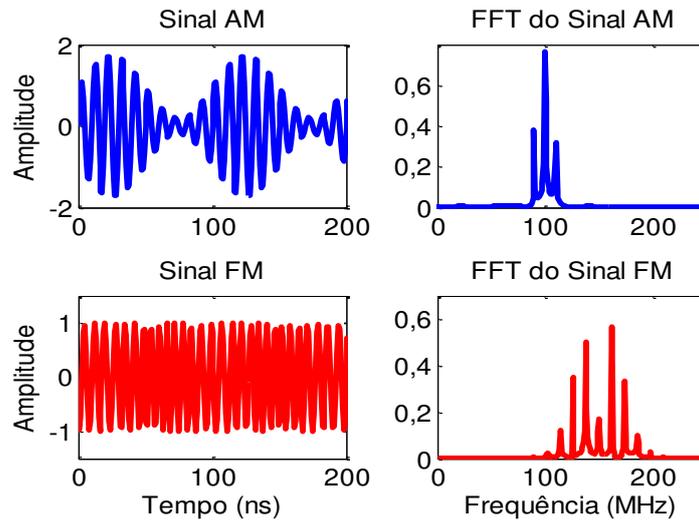


Figura 17 – Sinais AM, FM e seus respectivos espectros de frequência.

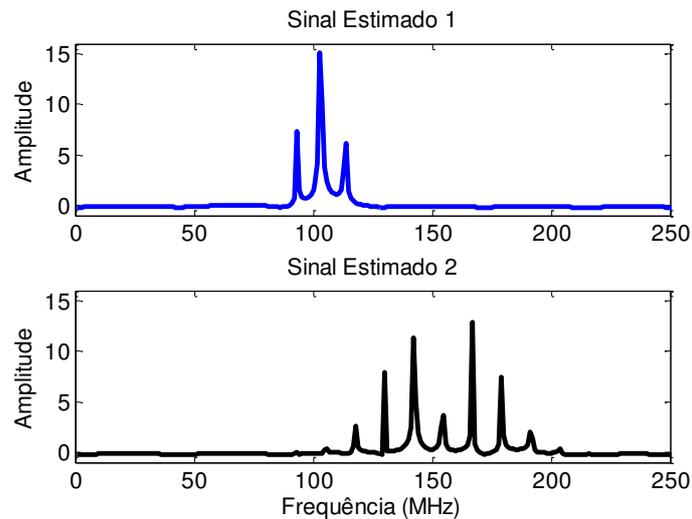


Figura 18 – Espectros estimados dos sinais AM e FM, respectivamente.

Comparando as Figuras 17 e 18 percebe-se que os sinais foram recuperados na mesma ordem dos sinais de entrada, ou seja, a primeira linha da Figura 18 corresponde ao sinal AM e o da segunda linha ao sinal FM. Os valores dos coeficientes de correlação foram elevados para ambos os sinais estimados (0,998 para o sinal FM e 0,996 para o sinal AM). Tais valores são superiores aqueles obtidos em [6]. Isso demonstra que o algoritmo programado também funciona para dados de entrada que estejam no domínio da frequência. A aplicação do ICA para os dados de entrada sendo espectros de potência pode resultar em inversão dos valores de amplitude, ou seja, raias com amplitudes que deveriam ser recuperadas com valores positivos podem aparecer com valores negativos, portanto, é preciso estar atento para esse fato.

4.5 Conclusão do Capítulo

O ICA tem aplicabilidade para vários tipos de sinais e não garante que os sinais estimados terão mesma amplitude e fase dos sinais originais, mas que terão o mesmo comportamento e podem ser reconhecidos mesmo misturados a outros sinais.

O uso do coeficiente de correlação possibilitou uma análise quantitativa entre os sinais estimados e os sinais originais, permitindo avaliar a qualidade da separação, quando as fontes originais estavam disponíveis.

A função custo g_3 deve ser a primeira função custo a ser considerada para se buscar a separação quando não se tem conhecimento da fdp dos sinais fontes.

Nos casos em que os sinais tinham pequena diferença de fase ($\Delta\theta = 1^\circ$) o ICA conseguiu separá-los mesmo eles sendo praticamente os mesmos, embora essa estimativa seja comprometida pelo deslocamento da fase dos sinais estimados em relação aos sinais originais.

O algoritmo FastICA pode ser aplicado para separar sinais cujos dados estejam no domínio da frequência ou do tempo.

Nos casos em que se tem ruído ele foi considerado como uma fonte. Nesta avaliação, somente os casos cujo número de sensores é igual ao número de fontes foram estudados.

Capítulo 5

5. Aplicação do ICA para Separação de Duas Fontes Irradiantes

Neste Capítulo será apresentada uma série de experimentos práticos, com antenas dipolo e log-periódicas como fontes, dispostas em várias configurações. O intuito é aplicar o método ICA para dados medidos. É apresentado modificações nos procedimentos de aplicação do ICA para o caso de fontes idênticas e espacialmente muito próximas. Com o objetivo de deixar evidentes os resultados e observações, cada Seção tratará de um experimento.

Na Seção 5.1 é descrito o ensaio com duas fontes idênticas, dispostas colinearmente uma atrás da outra e próximas. Na Seção 5.2 o experimento é realizado com as mesmas fontes, mas com frequências diferentes. A Seção 5.3 traz o ensaio com fontes de frequências iguais, mas na configuração de fontes lado a lado. Na Seção 5.4 é feito o ensaio variando a distância entre as antenas e avaliado o resultado da separação pela ICA. A Seção 5.5 expõe o ensaio em que se têm fontes ditas ativas acompanhadas de elementos passivos próximos. Experimentos com duas fontes com frequências próximas ($\Delta F = 0,63\%$) são tratados na Seção 5.6. Já na Seção 5.7 é feito um estudo do deslocamento de polarização entre as fontes (antenas transmissoras) e os sensores (antenas receptoras), na resposta do ICA. Na Seção 5.8 é apresentada a conclusão do capítulo.

Nos primeiros 5 experimentos foram usadas duas antenas dipolo de meio comprimento de onda, projetadas para operar na frequência de 1,80 GHz (comprimento de onda $\lambda_0 = 16,67$ cm), sendo estas, as fontes transmissoras. Nos experimentos 6 e 7 foram usadas duas antenas log-periódicas planares, (BW = 1,7 GHz) operando na frequência de 1,60 GHz ($\lambda_0 = 18,75$ cm). Para captar os sinais irradiados, foi usada uma antena log-periódica *Rhode & Schwartz (R&S)*, HL040: 0,40 – 2,70 GHz. As medições foram realizadas no

espaço aberto do ambiente do LEMA (Laboratório de Eletromagnetismo Aplicados), localizado na UFCG, *campus* – Campina Grande.

5.1 Experimento 1: Duas Antenas Alimentadas com o mesmo Sinal e Dispostas Uma Atrás da Outra

Nesse experimento as duas antenas dipolo foram alinhadas uma atrás da outra, em relação ao eixo x (ver Figura 19), e separadas de uma distância de aproximadamente um quarto de comprimento de onda (4,25 cm), (distância escolhida aleatoriamente). Nelas foi injetado um sinal senoidal com mesma frequência, mesma fase e mesma amplitude, produzidos a partir de um gerador de sinais da *R&S*, modelo SMBV 100A (9 kHz – 6 GHz).

O sinal CW (onda contínua) produzido pelo gerador tem potência de -5 dBm na frequência de 1,80 GHz. Esse sinal foi dividido usando um conector tipo T e conectado a cada antena por meio de dois cabos coaxiais de mesmo tamanho (1,10 m).

Inicialmente as medições foram feitas usando um analisador de espectro da *Agilent Technologies* modelo N1996A (100 kHz – 3 GHz), sintonizado na faixa de 1,70 – 1,90 GHz, escala de amplitude em dBm. Também foi usado um analisador de espectro da *R&S* modelo FSL6 (9 kHz – 6 GHz), operando entre 1,00 e 1,70 GHz.

5.1.1 Procedimentos de Medição

Na Figura 19 é ilustrado o esquema de medições para os experimentos e o sinal emitido pelas fontes S_I e S_{II} individualmente. Os dois cabos coaxiais usados apresentam impedância de 50Ω . Inicialmente foi usada a antena log-periódica, conectada ao analisador de espectro, para medir o espectro de amplitude (dBm) do sinal das fontes (antenas transmissoras Tx). No primeiro procedimento S_I encontra-se ligada e S_{II} retirada da montagem. Em seguida, S_{II} é ligada e S_I retirada da montagem. Esses sinais são tomados como referência para posterior comparação com a resposta do ICA. A antena receptora (Rx) foi colocada em duas posições diferentes distantes das antenas fontes (transmissoras) com as duas antenas S_I e S_{II} ligadas. As posições de

medição foram escolhidas aleatoriamente, na região de campos distantes (RCD). Na primeira posição colocou-se a antena Rx no mesmo eixo das antenas transmissoras (eixo x), posição P1. Na segunda medição Rx ficou à $\theta = 45^\circ$ do eixo principal das antenas (plano XY), posição P2.

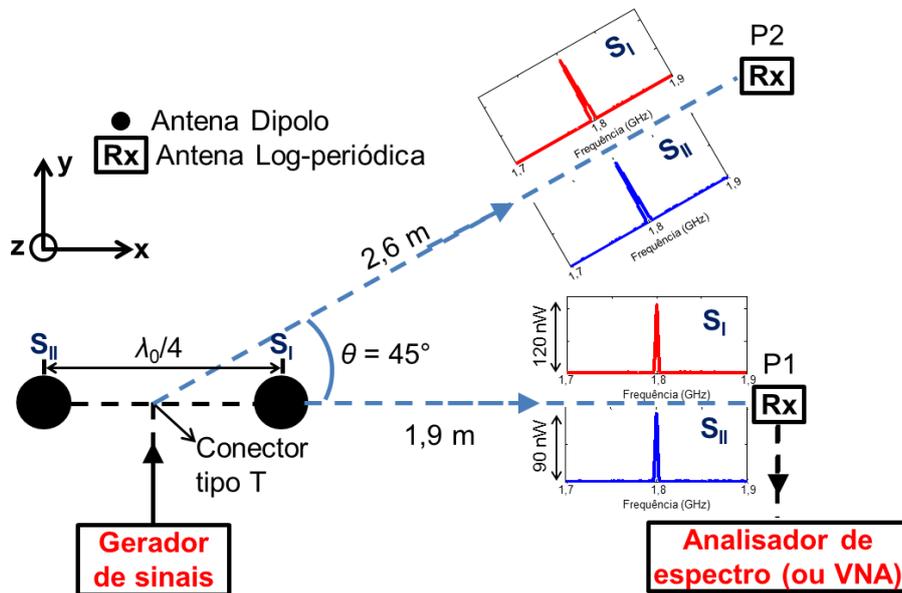


Figura 19 – Esquema de medições para o experimento 1.

Antes de entrar com os dados das medições no algoritmo FastICA, a escala logarítmica (dBm), medida pelo analisador de espectro, foi convertida para a escala linear (*Watts*). Na Figura 20.a, são apresentados o sinal total medido nas posições P1 e P2, com as duas antenas excitadas ao mesmo tempo. Foi utilizada apenas uma antena receptora, portanto, mediu-se primeiro os sinais na posição 1 e em seguida deslocou-se a antena para a posição P2. O vetor de medidas aleatórias \mathbf{x} em (3.1) é preenchido com os dados vistos na Figura 20.a e o resultado dos sinais estimados, ou seja, das componentes independentes é exposto na Figura 20.b.

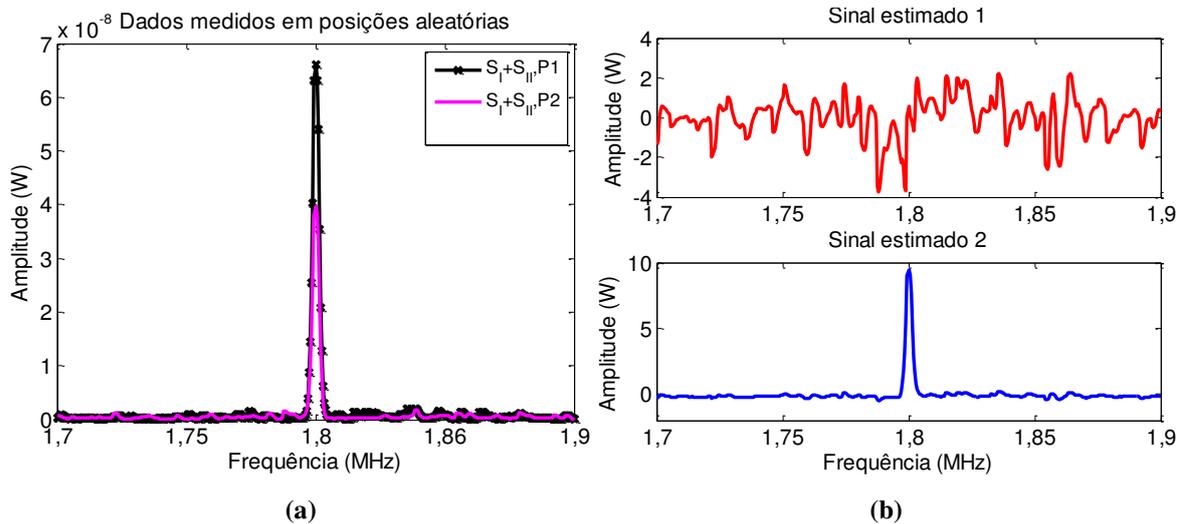


Figura 20 – (a) Espectro emitido pelas duas antenas, ao mesmo tempo, medido nas posições 1 e 2; (b) Sinais estimados (recuperados) pelo ICA, a partir dos dados da Figura 20.a.

Os sinais obtidos, após o processamento pelo ICA, não são semelhantes aos sinais emitidos pelas duas antenas (S_I e S_{II}). Quando comparado o sinal estimado 2 (Figura 20.b) com o sinal emitido por S_I , obtêm-se um coeficiente de correlação de 0,993. Quando comparado ao sinal de S_{II} , o coeficiente de correlação é de 0,992. Isso indica que o algoritmo não conseguiu distinguir se o sinal estimado 2 é referente ao sinal de S_I ou de S_{II} . Portanto, o ICA não conseguiu distinguir a existência das duas fontes: um sinal emitido pela antena S_I e outro emitido por S_{II} . Isso indica que não foi possível, com esse procedimento de medição, fornecer subsídios para que o ICA seja capaz de separar as duas fontes irradiantes nessa configuração. A outra resposta fornecida pelo ICA (diferente de S_I e S_{II}) denominou-se simplesmente de um sinal de ruído [65]. Visando solucionar o problema da não separação das fontes, nesse experimento, os procedimentos foram modificados como descrito a seguir.

5.1.2 Proposta de Modificação nos Procedimentos de Medição

Usando a mesma configuração vista na Figura 19, substituiu-se o analisador de espectro por um analisador de redes vetorial (VNA), *R&S*, modelo ZVB20 (10 MHz – 20 GHz). Com ele foi medido o espectro, além da amplitude a fase do coeficiente de transmissão (S_{21}) de cada antena

transmitindo, em seguida do conjunto. O procedimento foi feito em cada posição. A substituição do analisador de espectro pelo VNA se deu pela necessidade de se ter uma informação a mais nas medições, a fase. Como visto na Seção 5.1.1, o ICA não conseguiu separar os dois sinais somente pela informação da amplitude dos sinais medidos, o que sugere a necessidade de coleta de outra informação dos sinais transmitidos, por exemplo, da fase. A partir dos dados de amplitude e fase, medidos nas duas posições, se reconstruiu cada sinal para a frequência de interesse, 1,80 GHz. O Sinal gerado no VNA é uma senoide em cada frequência, na faixa de 1,70–1,90 GHz.

Para o sinal transmitido pela antena S_I , observou-se, na frequência de 1,80 GHz uma amplitude de $-36,5$ dB e uma fase de 166° . No caso de S_{II} a amplitude foi de $-36,3$ dB e a fase de 150° . É preciso converter de dB para *Watts* e depois usar a expressão (5.1), para determinar a amplitude da tensão (considerando $R = 50 \Omega$, para a impedância de entrada do VNA).

$$P = \frac{V^2}{R} \rightarrow V = \sqrt{PR}. \quad (5.1)$$

Logo, o sinal reconstruído para a antena S_I e S_{II} será, respectivamente:

$$\text{Sinal}_{S_I} = 0,106\text{sen}(\omega t + 166), \quad \text{Sinal}_{S_{II}} = 0,108\text{sen}(\omega t + 150).$$

Na Figura 21, são mostrados os gráficos dos sinais transmitidos pelas antenas S_I e S_{II} , individualmente e, os sinais medidos nas posições P1 e P2 para as duas antenas excitadas ao mesmo tempo, após o processo descrito acima.

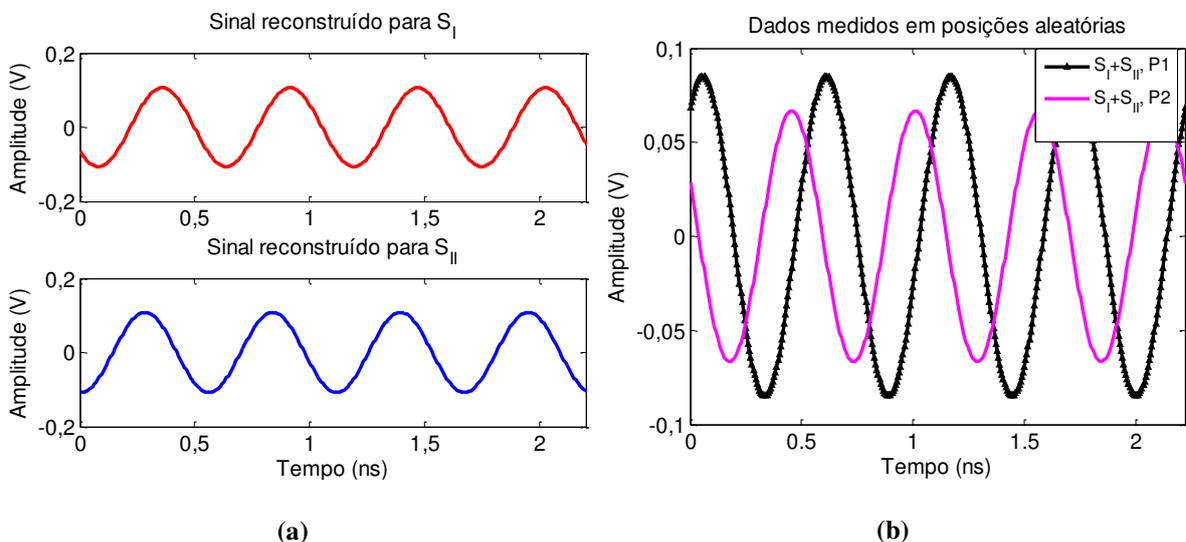


Figura 21 – (a) Sinais transmitidos e reconstruídos matematicamente para as antenas S_I e S_{II} ; (b) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2.

Ao ICA foram fornecidos os dados referentes às medições feitas nas posições P1 e P2, com as duas antenas excitadas ao mesmo tempo (Figura 21.b). O resultado dos sinais estimados, isto é, das componentes independentes é mostrado na Figura 22.

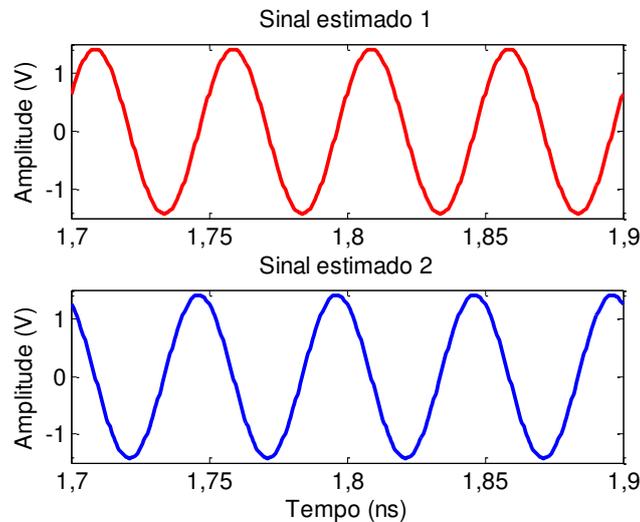


Figura 22 – Sinais recuperados (estimados) pelo ICA, a partir dos dados da Figura 21.b.

Quando comparado o sinal estimado 1 (Figura 22) com o sinal transmitido e reconstruído matematicamente, da antena S_I (Figura 21.a), obtêm-se um coeficiente de correlação de $-0,983$. Quando comparado o sinal estimado 2 com o sinal reconstruído matematicamente da antena S_{II} , o coeficiente de correlação é igual a $-0,863$. Isso indica que há uma forte correlação linear entre o sinal estimado e o sinal original. Portanto, o ICA conseguiu distinguir a presença das duas fontes. As mudanças nos procedimentos resultaram em uma extensão da aplicação do ICA. Portanto, para o caso de identificação e separação de duas fontes irradiantes semelhantes e fisicamente muito próximas requer que nos dados de entrada do ICA, constem a amplitude e fase.

5.2 Experimento 2: Duas Antenas Alimentadas com Sinais Diferentes e Dispostas Uma Atrás da Outra

Neste experimento as antenas foram alinhadas da mesma maneira que na Figura 19, mas foram alimentadas com sinais de frequências diferentes. Nelas foi injetado um sinal senoidal com potência de -5 dBm nas frequências: $F_{SI} = 1,837$ GHz e $F_{SII} = 1,800$ GHz, respectivamente. As

frequências foram escolhidas considerando a faixa de operação das antenas transmissoras. Todas as medições foram feitas usando um analisador de espectro, sintonizado na faixa de 1,70 – 1,90 GHz, com escala de amplitude em dBm. Os mesmos procedimentos de medição descritos na Seção 5.1.1 foram utilizados nesse experimento. Na Figura 23.a, é apresentado o sinal injetado nas antenas fontes (Tx), ambos medidos na posição P1 (Figura 19). Na Figura 23.b pode ser visto os sinais medidos nas posições P1 e P2 (Figura 19), simultaneamente.

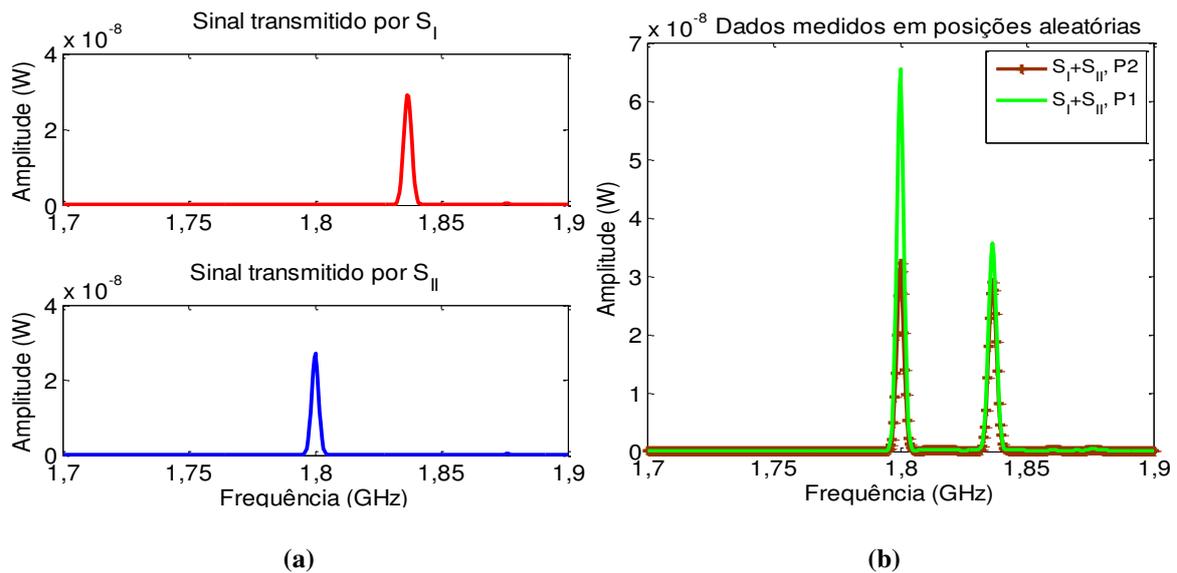


Figura 23 – Espectro transmitido por S_I e por S_{II}, individualmente; (b) Espectro emitido pelas antenas Tx e medido nas posições P1 e P2.

Ao ICA devem ser fornecidos os dados do espectro medido nas posições P1 e P2 (Figura 23.b). O resultado dos sinais estimados é mostrado na Figura 24.

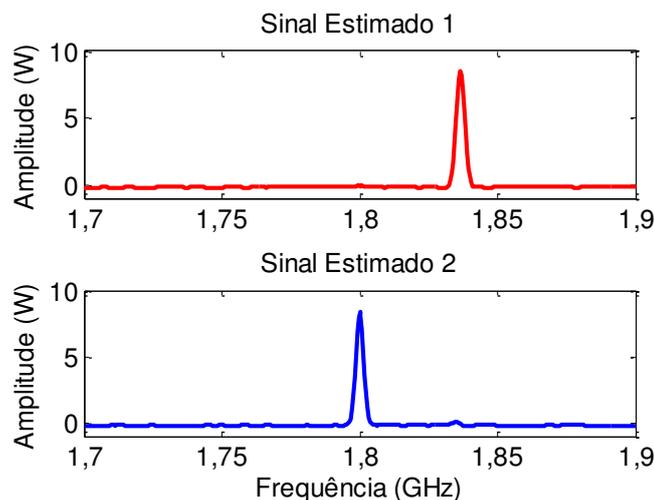


Figura 24 – Sinais estimados pelo ICA, a partir dos dados da Figura 23.b.

Os sinais obtidos após o processamento pelo ICA são semelhantes aos sinais emitidos pelas duas antenas (S_I e S_{II}). Como pode ser observado na Figura 24, o ICA conseguiu separar as fontes S_I e S_{II} , como esperado. Logo, ele é capaz de separar sinais de duas fontes irradiantes próximas, uma atrás da outra, e alimentadas com sinais de diferença pequena em amplitude e frequência, $\approx 2\%$ ($F_{SI} = 1,837$ GHz e $F_{SII} = 1,800$ GHz). Esse resultado está de acordo com simulações para dois sinais senoidais com as mesmas características apresentadas no experimento.

Quando comparado o sinal estimado 1 (Figura 24) com o sinal emitido por S_I (Figura 23.a), obtêm-se um coeficiente de correlação de 0,972. Comparando o sinal emitido por S_{II} com o sinal estimado 2, obtêm-se 0,983 como coeficiente de correlação. Demonstrando que há uma forte correlação entre os sinais estimado e original. Assim, o ICA pode separar fontes eletromagnéticas fisicamente próximas e com uma pequena diferença em frequência.

Teoricamente [4] o ICA não pode separar dois sinais com mesma frequência, se eles não forem independentes, mas na prática foi conseguindo a separação para sinais com ΔF de 2%. Isso se deve ao fato de que os sinais possuem uma largura de banda, BW, mínima para serem gerados nos equipamentos.

Outro caso estudado nesse experimento foi dispor as fontes lado a lado, também distantes $d = \lambda_0/4$, com frequências $F_{SI} = 1,837$ GHz e $F_{SII} = 1,800$ GHz. Nesta situação o ICA também conseguiu separar as fontes (resultado não apresentado aqui devido a sua simplicidade).

5.3 Experimento 3: Duas Antenas Excitadas com Sinais Iguais, Dispostas Lado a Lado

Nesse experimento as antenas foram alinhadas lado a lado (tomando como referência a antena (Rx) receptora, localizada no eixo x – ver Figura 25) e separadas por uma distância de aproximadamente um décimo de comprimentos de onda (1,67 cm). Nessa situação as antenas estão muito próximas, além de serem excitadas pelo mesmo sinal, que como visto na Seção

5.1 apresenta dificuldades na aplicação do ICA quando usado o analisador. Portanto, o objetivo deste experimento é verificar se os procedimentos propostos na Seção 5.1.2 se aplicam para fontes distantes $d \ll \lambda_0$. Situação que não foi estudada em outras referências que tratam de fontes irradiantes e se configura numa situação de sobreposição de sinais devido à pequena distância entre as fontes.

Na Figura 25 é mostrado o esquema de medição, com os respectivos sinais emitidos pelas fontes (sinais de referência) e os sinais resultantes da sobreposição de S_I e S_{II} nas posições P1 e P2. O esquema é composto por um analisador de redes vetorial (VNA) da R&S, modelo ZVB20 (10 MHz – 20 GHz), duas antenas dipolo, uma antena log-periódica R&S, HL040, um conector divisor tipo T e dois cabos coaxiais de mesmo tamanho (1,10 m), com impedância de 50 Ω . A fonte de alimentação das antenas foi obtida a partir do VNA que gera um sinal sinusoidal, para cada frequência na faixa de 1,70 – 1,90 GHz, com a mesma amplitude.

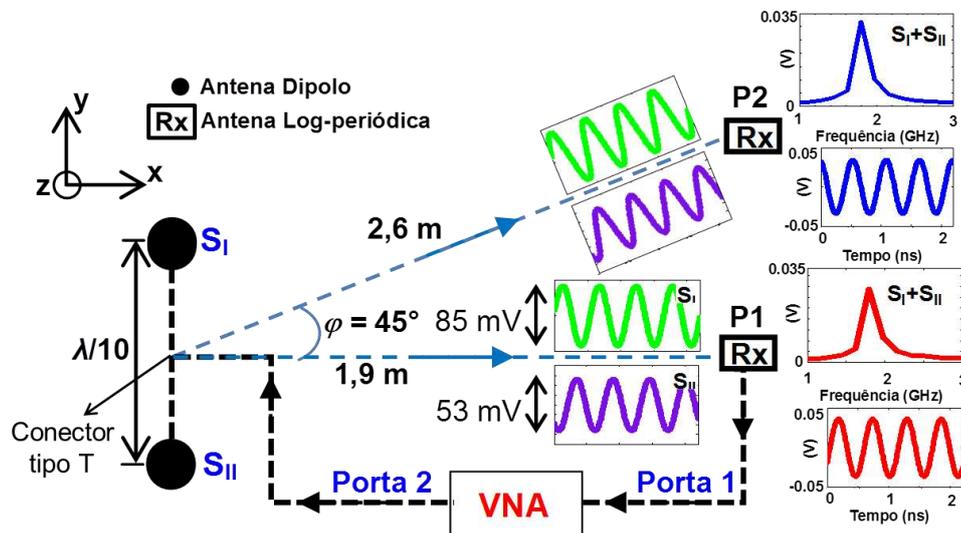


Figura 25 – Esquema de medição para o experimento 3.

As posições de Rx foram escolhidas aleatoriamente, de modo a facilitar as medições. Na primeira posição colocou-se a antena Rx em frente ao eixo perpendicular as antenas transmissoras (eixo x), na segunda posição, Rx foi deslocada a $\varphi = 45^\circ$ do eixo x , no plano XY. Na Figura 26.a é mostrado os sinais transmitidos por S_I e S_{II} ambas ligadas ao mesmo tempo, medidos nas posições P1 e P2. Já na Figura 26.b são apresentados os sinais obtidos pelo ICA a partir dos dados da Figura 26.a.

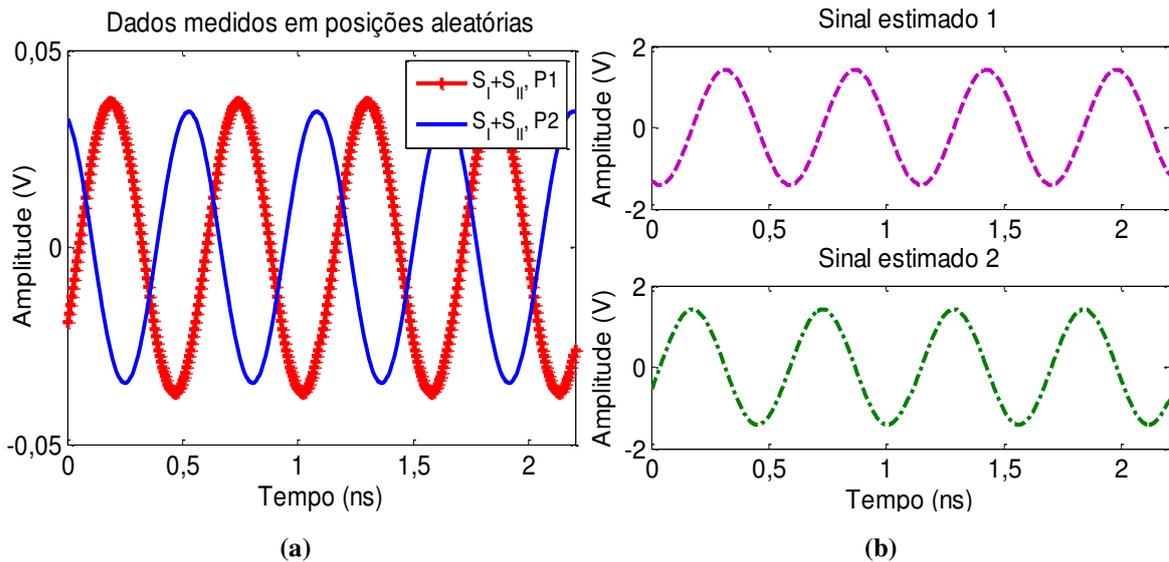


Figura 26 – (a) Sinais reconstruídos a partir dos dados medidos nas posições P1 e P2, com S_I e S_{II} excitadas ao mesmo tempo; (b) Sinais estimados pelo ICA, a partir dos dados da Figura 26.b.

O resultado visto na Figura 26.b demonstra que o ICA conseguiu separar as fontes S_I e S_{II} , como esperado. Portanto, ele também é capaz de separar sinais com pequenas diferenças de fase e em condições de sobreposição, devido à pequena distância entre as fontes.

Comparado o sinal estimado 2 (Figura 26.b) com o sinal emitido por S_I (Figura 25), obtêm-se um coeficiente de correlação de 0,853 e comparando o sinal emitido por S_{II} com o sinal estimado 1, obtêm-se 0,914. Os valores elevados dos coeficientes de correlação confirmam que os sinais originais foram recuperados pelo ICA. No caso de uma correlação cruzada (sinal estimado 2 com S_{II} e o sinal estimado 1 com S_I) obteve-se valores inferiores a 0,020, ou seja, não há correlação linear entre esses sinais. Portanto, eles são diferentes.

O esquema de medição visto na Figura 25 foi alterado para o caso das fontes estarem dispostas uma atrás da outra, como no experimento da Seção 5.1 (Figura 19), mantendo-se a distância entre as fontes em $\lambda_0/10$ e mesma excitação. Os objetivos deste experimento são: verificar se a posição relativa das fontes e; se a pequena distância entre elas influenciam na resposta do ICA. Em outras palavras, se o ICA é capaz de separar as fontes, nessa segunda situação. Os sinais emitidos, individualmente, pelas fontes S_I e S_{II} (medidos na posição P1), juntamente com os dados misturados, medidos

nas posições P1 e P2 (S_I e S_{II} ligadas ao mesmo tempo), são mostrados na Figura 27, respectivamente.

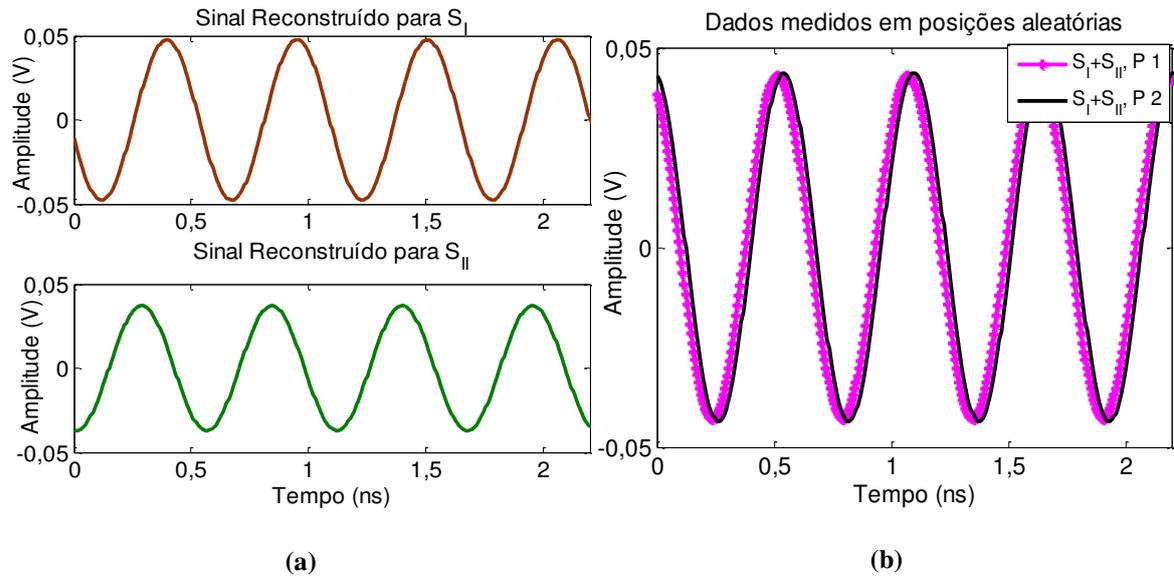


Figura 27 – (a) Sinais emitidos pelas fontes S_I e S_{II} , individualmente; (b) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2, S_I e S_{II} excitadas ao mesmo tempo.

Os sinais vistos na Figura 28 foram obtidos pelo ICA a partir dos dados da Figura 27.b.

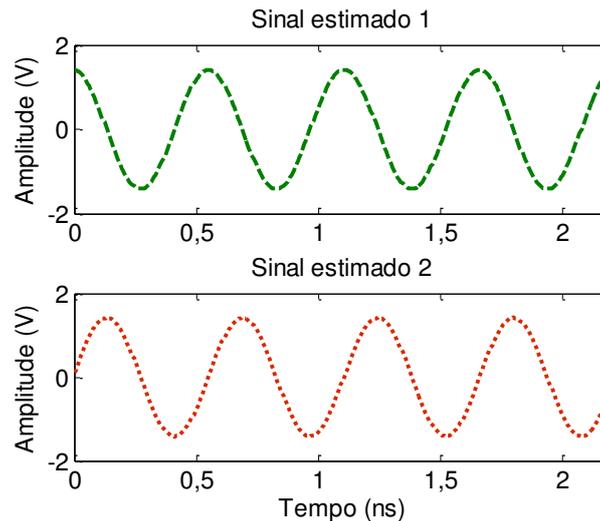


Figura 28 – Sinais estimados pelo ICA, a partir dos dados da Figura 27.b.

Comparando os sinais estimados (Figura 28) com os sinais emitidos por S_I e S_{II} (Figura 27.a) observa-se que houve inversão de fase e de ordem, mas os sinais têm o mesmo comportamento. O coeficiente de correlação entre os sinais S_I e estimado 2 foi de $-0,983$; para os sinais S_{II} e estimado 1 o coeficiente de correlação foi de $-0,985$. Confirmando a elevada correlação linear entre os sinais estimados e originais.

Nas duas configurações trabalhadas, nesse experimento, foi possível observar que, em termos de separação das fontes, o ICA conseguiu separá-las independente de como elas foram dispostas no espaço. Resumidamente o ICA pode ser aplicado para separar fontes irradiantes muito próximas, estejam elas dispostas lado a lado ou uma atrás da outra, de forma satisfatória.

5.3.1 Experimento 3.1: Duas Fontes Idênticas, Dispostas Uma Atrás da Outra e Distantes $\lambda_0/10$

Este experimento é uma complementação do experimento 3 com a modificação de uma das posições da antenna receptora (Rx) e da antenna S_{II} . A antenna Rx foi colocada a $\theta = 90^\circ$ em relação ao eixo x , ou seja, perpendicular às antenas fontes (transmissoras Tx). Nessa situação os sinais misturados têm a mesma amplitude e nenhuma diferença de fase ($\Delta\psi = 2\pi d \sin\theta/\lambda$). Isso representa uma situação de sobreposição no receptor e, portanto, uma maior dificuldade para separar os sinais [66]. Não se tem, teoricamente, diferença de fase entre os sinais que chegam à antenna receptora. O objetivo deste experimento é estudar a influência do posicionamento da antenna receptora (ou seja, do sensor) na resposta do ICA. Para tal, foi usado o esquema de medição mostrado na Figura 29.

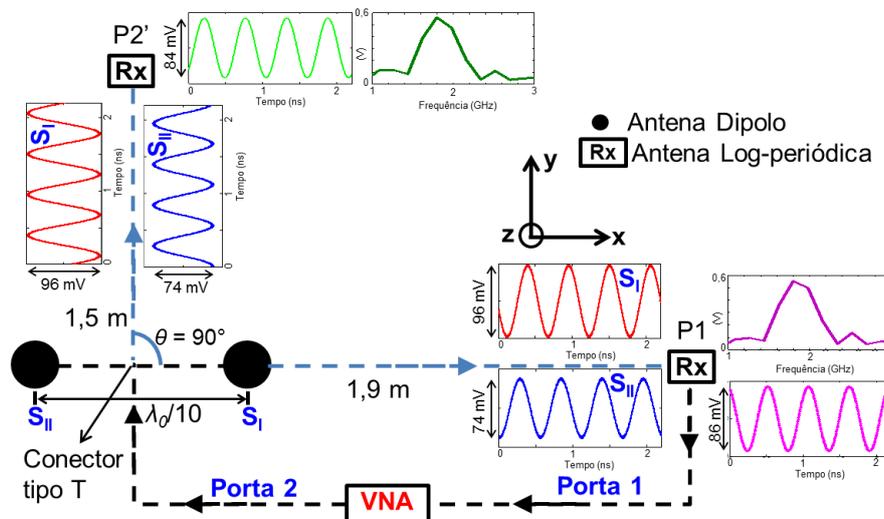


Figura 29 – Esquema de medição para o experimento 4.

Os mesmos procedimentos descritos na Seção 5.1.2 também foram usados aqui. Os dados medidos, com S_I e S_{II} excitadas ao mesmo tempo

(medidos nas posições P1 e P2') e, o resultado da aplicação do ICA sobre esses dados são expostos na Figura 30.

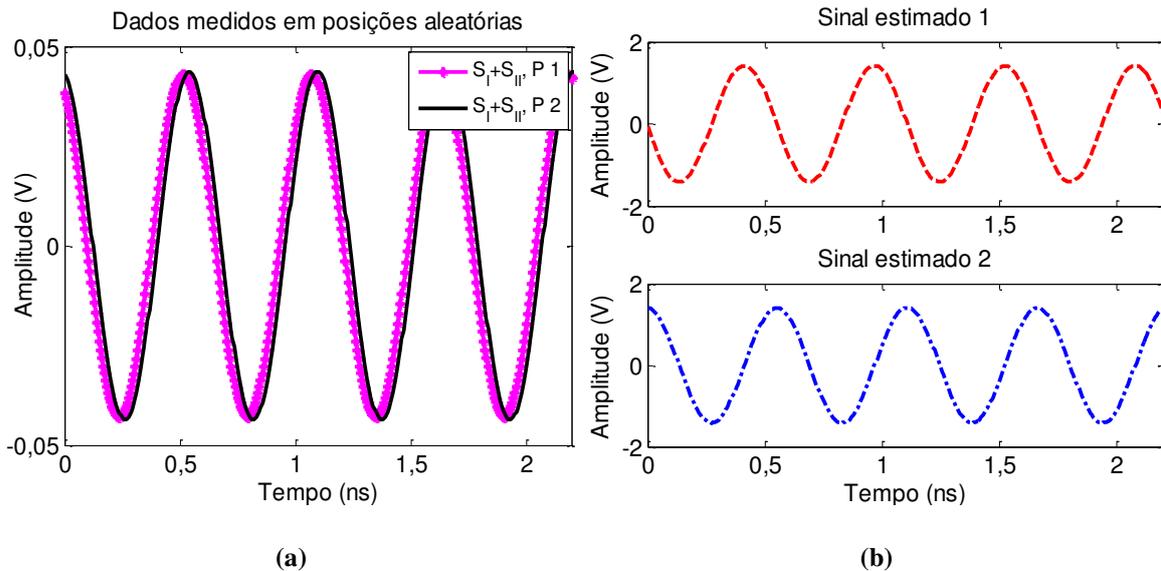


Figura 30 – (a) Sinais reconstruídos matematicamente a partir dos dados medidos nas posições P1 e P2' (90° do eixo x); (b) Sinais estimados a partir dos dados da Figura 30.a.

Quando são comparados os sinais estimados (Figura 30.b) com os sinais de referência (Figura 29), obtêm-se coeficientes de correlação elevados: entre os sinais estimado 1 e S_I tem-se 0,981; entre os sinais estimado 2 e S_{II} tem-se $-0,986$. Resultado idêntico ao obtido quando se dispôs as antenas fonte lado a lado, como na Figura 25, e se colou a antena receptora (Rx) a 90° do eixo x , como na Figura 29.

É possível concluir, da análise dos valores obtidos para os coeficientes de correlação, que a posição relativa da antena receptora (se 45° ou 90° em relação ao eixo x) não influencia a resposta do ICA, ou seja, é possível separar e identificar as fontes independentemente da posição dos sensores. Essa informação poderá ser usada para solucionar um dos problemas de estimação com precisão da direção de chegada, que é a necessidade de se ter arranjos com antenas a uma distância fixa de $\lambda_0/2$, para evitar ambiguidade de fase [67]. Além do fato que aqui foi usado apenas duas antenas ao invés de um arranjo.

5.4 Experimento 4: Variação da Distância entre Duas Antenas Iguais, Dispostas uma Atrás da Outra

Neste experimento a distância entre as antenas foi variada em comprimentos de onda. O objetivo é verificar se a resposta do ICA é influenciada pela distância entre as fontes (mantendo-se a mesma posição da antena receptora) e, se é possível identificar a distância entre elas, a partir dos sinais separados pelo ICA. Para tal, foi usado o mesmo esquema de medição do experimento 1 (Figura 19) e os procedimentos descritos na Seção 5.1.2, ou seja, foram medidas a fase e amplitude do coeficiente S_{21} e depois reconstruído matematicamente os sinais para a frequência de 1,80 GHz ($\lambda_0 = 16,67$ cm).

As distâncias usadas no experimento foram: $d_1 = \lambda_0/4 = 4,25$ cm; $d_2 = 3\lambda_0/8 = 6,25$ cm; $d_3 = \lambda_0/2 = 8,4$ cm; $d_4 = 3\lambda_0/4 = 12,5$ cm; $d_5 = 5\lambda_0/4 = 20,9$ cm; $d_6 = 7\lambda_0/4 = 29,4$ cm. A ideia é que a diferença de fase entre os sinais separados pelo ICA corresponda, em comprimentos de onda, aos valores da distância física entre as antenas fontes (transmissoras Tx). Os sinais emitidos e reconstruídos matematicamente para as antenas S_I e S_{II} , medidos na posição P1, são expostos na Figura 31. Esses sinais são tomados como referência para fazer o processo de comparação com as componentes independentes obtidas pelo ICA.

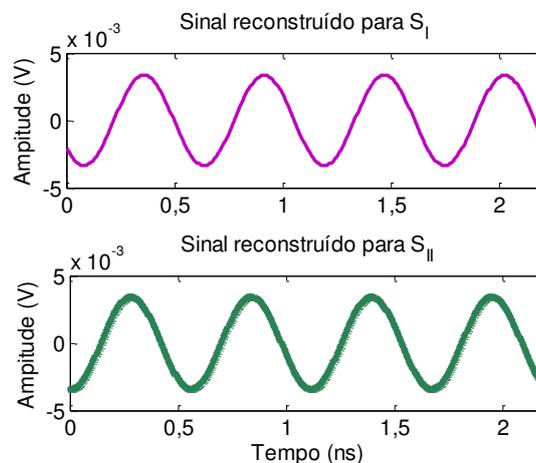


Figura 31 – Sinais fontes, reconstruídos matematicamente a partir dos dados medidos na posição P1.

Nas Subseções a seguir serão apresentadas as medições, nas posições P1 e P2, e os resultados obtidos após o processamento pelo ICA, para as distâncias descritas acima.

5.4.1. Resultados para $d_1 = \lambda_0/4$

As antenas foram postas a uma distância de $d_1 = 4,25$ cm. Na Figura 32 são mostrados os sinais reconstruídos a partir das medições feitas nas posições P1 e P2 e os sinais estimados pelo ICA a partir dos dados da Figura 32.a.

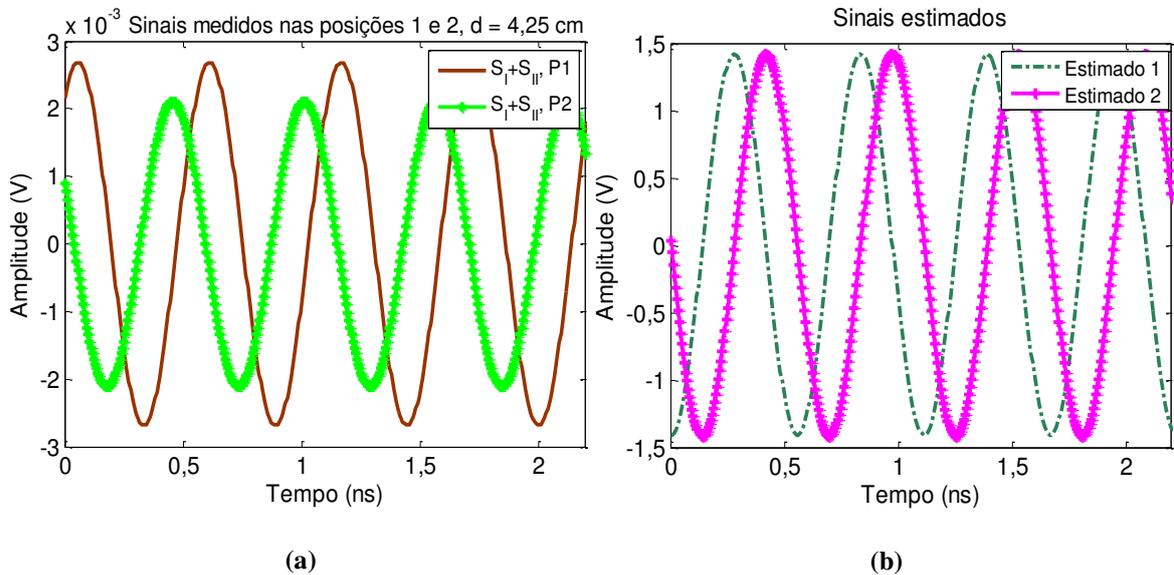


Figura 32 – (a) Sinais reconstruídos matematicamente para as fontes distantes $\lambda_0/4$; (b) Sinais estimados a partir dos dados da Figura 32.a.

Usando procedimento matemático simples (regra de três) foi determinada a diferença de fase entre os dois sinais estimados. O período de 0,556 ns corresponde a 360° (ou um comprimento de onda), logo 0,144 ns (diferença temporal entre os sinais estimados 1 e 2) corresponde a $93,24^\circ$. Este valor representa $0,26\lambda_0$ (4,33 cm), ou seja, uma diferença de 1,88% em relação à distância física original entre as duas antenas. Isso a princípio leva a crer que, com a ajuda do ICA, se pode inferir a distância entre as fontes, nesta configuração. Em termos de coeficiente de correlação obteve-se: entre S_I e o sinal estimado 1 = 0,988 e entre S_{II} e o sinal estimado 2 = 0,848.

5.4.2. Resultados para $d_2 = 3\lambda_0/8$

A distância entre as antenas foi ajustada para $d_2 = 6,25$ cm. Na Figura 33 são mostrados os sinais reconstruídos a partir das medições feitas nas posições P1 e P2 e os sinais estimados pelo ICA a partir dos dados da Figura 33.a.

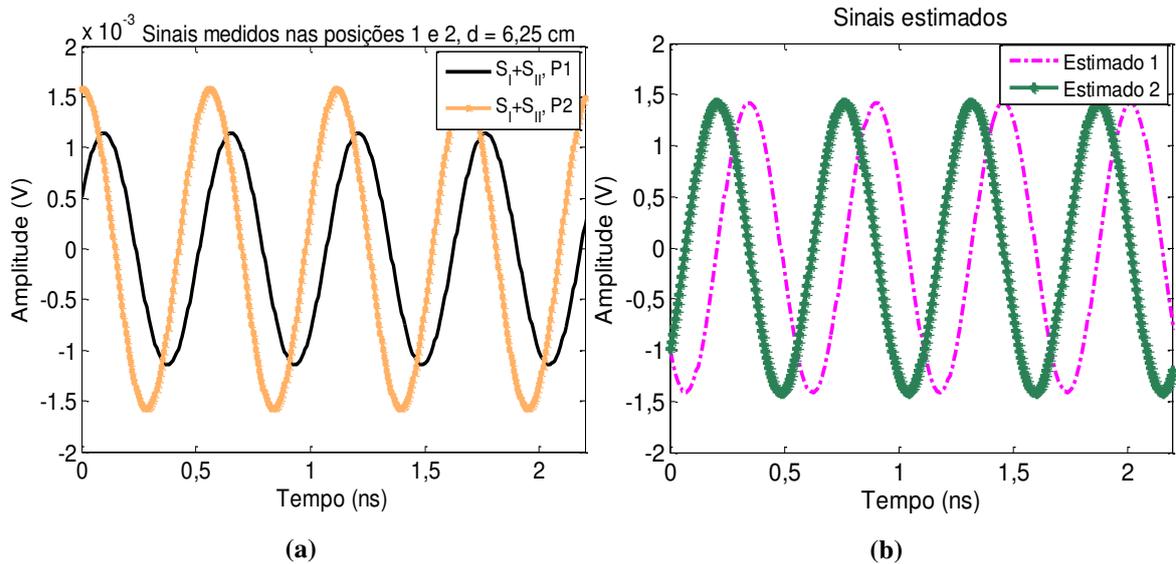


Figura 33 – (a) Sinais reconstruídos matematicamente para as fontes distantes $3\lambda_0/8$; (b) Sinais estimados a partir dos dados da Figura 33.a.

A diferença de fase entre os dois sinais estimados foi de 90° . O que corresponde a 0,139 ns (diferença temporal entre os sinais estimados 1 e 2). Esse valor representa $0,25\lambda_0$ (4,25 cm), ou seja, uma diferença de 28,0% em relação à distância física original entre as duas antenas, ou seja, não se pode usar o ICA para inferir a distância entre as fontes, nessa situação. Em termos de coeficiente de correlação obteve-se: entre S_I e o sinal estimado 1 = 0,981; entre S_{II} e o sinal estimado 2 = 0,773.

5.4.3. Resultados para $d_3 = \lambda_0/2$

As antenas foram separadas de $d_3 = 8,4$ cm. Na Figura 34 são mostrados os sinais reconstruídos a partir das medições feitas nas posições P1 e P2 e os sinais estimados pelo ICA a partir dos dados da Figura 34.a.

A diferença de fase entre os sinais estimados foi a mesma que no experimento 5.4.2, ou seja, 90° . Esse valor representa uma diferença de 46,4% em relação à distância física original entre as duas antenas, portanto, não se pode usar o ICA para inferir a distância entre as fontes, também nesta situação. Em termos de coeficiente de correlação obteve-se: entre S_I o sinal e estimado 2 = $-0,987$ e entre S_{II} e o sinal estimado 1 = $-0,849$.

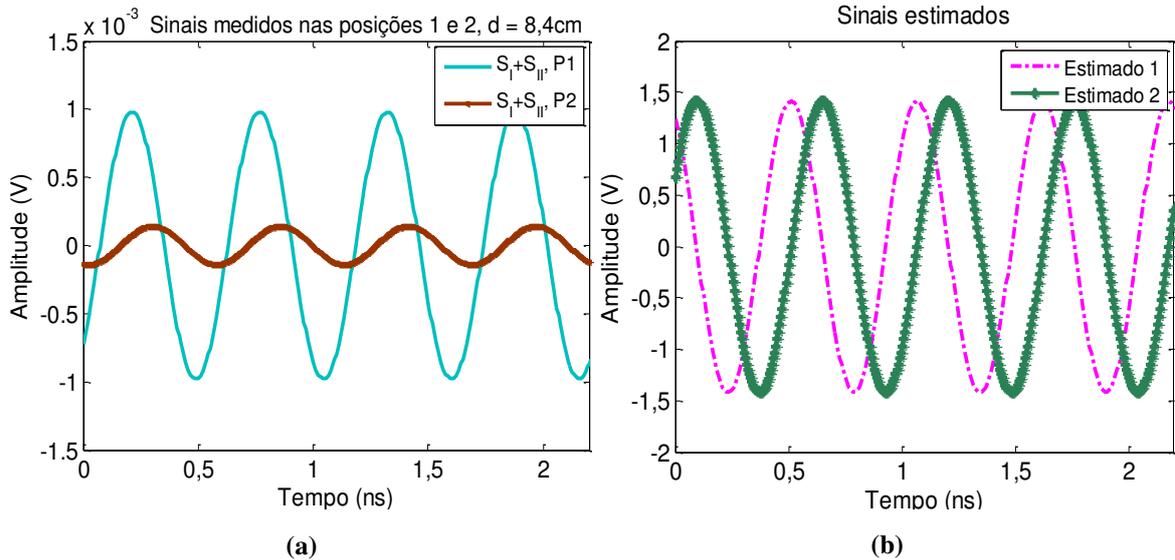


Figura 34 – (a) Sinais reconstruídos matematicamente para as fontes distantes $\lambda_0/2$; (b) Sinais estimados a partir dos dados da Figura 34.a.

5.4.4. Resultados para $d_4 = 3\lambda_0/4$

Aqui, as antenas foram separadas de $d_4 = 12,5$ cm e os resultados das medições e aplicação do ICA são expostos na Figura 35, respectivamente.

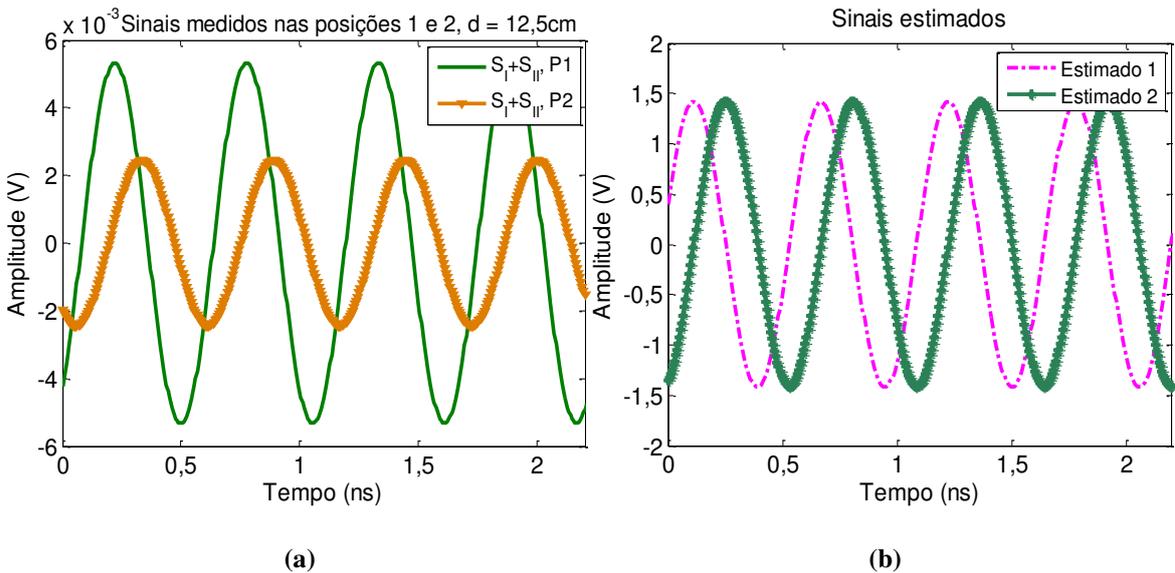


Figura 35 – (a) Sinais reconstruídos matematicamente para as fontes distantes $3\lambda_0/4$; (b) Sinais estimados a partir dos dados da Figura 35.a.

Como para o caso das distâncias anteriores, a diferença de fase entre os sinais estimados foi de 90° , o que representa uma diferença de 64,0% em relação à distância física original entre as duas antenas. Portanto, não se pode usar o ICA para inferir a distância também nessa situação. Em termos

de coeficiente de correlação obteve-se: entre S_I e o sinal estimado $1 = -0,932$ e entre S_{II} e o sinal estimado $1 = 0,942$.

Para evitar repetições na apresentação dos resultados, foi observado comportamento semelhante para os casos: $d_5 = 5\lambda_0/4 = 20,9$ cm; $d_6 = 7\lambda_0/4 = 29,4$ cm. Também para essas distâncias, a diferença de fase entre os sinais estimados foi de 90° . Obtiveram-se coeficientes de correlação também elevados, nessas duas situações.

Pode-se concluir que a mesma diferença de fase (90°) entre as componentes independentes (sinais estimados) é sempre mantida. Portanto, não se pode usar diretamente o resultado do ICA para inferir a distância física entre as duas antenas. Isso se deve ao fato de que as componentes estimadas pelo ICA passam por um processo de ortogonalização que produz a mesma defasagem de 90° entre elas. Assim, o ICA não consegue reproduzir a mesma diferença de fase entre as fontes originais. Porém, se os valores da matriz de separação W puderem ser acessados e a partir deles retirar essa defasagem, talvez seja possível usar o ICA para inferir a distância entre as fontes.

5.5 Experimento 5: Uma Antena Ativa, com Refletor Passivo

Para realizar este experimento utilizou-se o esquema de medição visto na Figura 36. Nele tem-se apenas uma das antenas transmissora ativa (S_I). Os procedimentos de medição foram os mesmos descritos na Seção 5.1.2. Este experimento é composto de duas partes: no primeiro momento o elemento refletor é uma antena dipolo; no segundo a antena foi substituída por um refletor retangular metálico (40 cm X 20 cm). O refletor foi colocado a $d = \lambda_0/4$ (4,25 cm) atrás da antena transmissora ativa (S_I). O objetivo aqui foi estudar se é possível determinar a existência de uma fonte e um elemento refletor nas proximidades, a partir dos resultados fornecidos pelo ICA e o coeficiente de correlação.

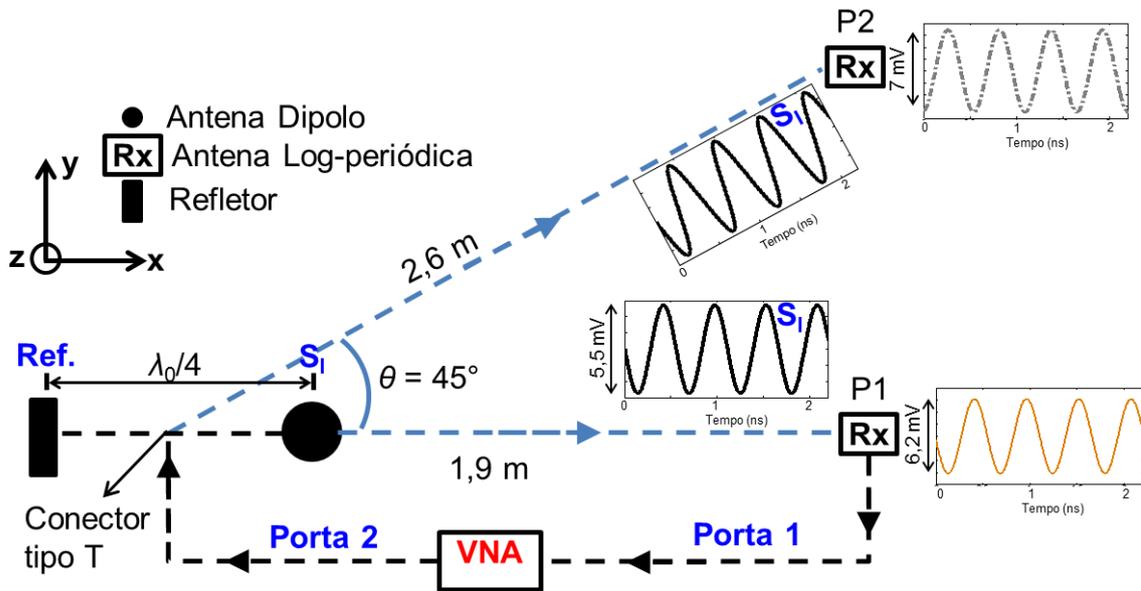


Figura 36 – Esquema de medição para uma fonte ativa e um refletor.

Inicialmente mediu-se o sinal transmitido pela antena S_I isoladamente, isto é, sem o refletor. Depois se colocou a antena dipolo sem alimentação atrás da antena S_I e mediu-se o sinal nas posições P1 e P2, cujo resultado é exposto na Figura 37 juntamente como o sinal estimado. Os sinais foram reconstruídos matematicamente a partir dos dados de amplitude e fase, medidos para a frequência de 1,80 GHz.

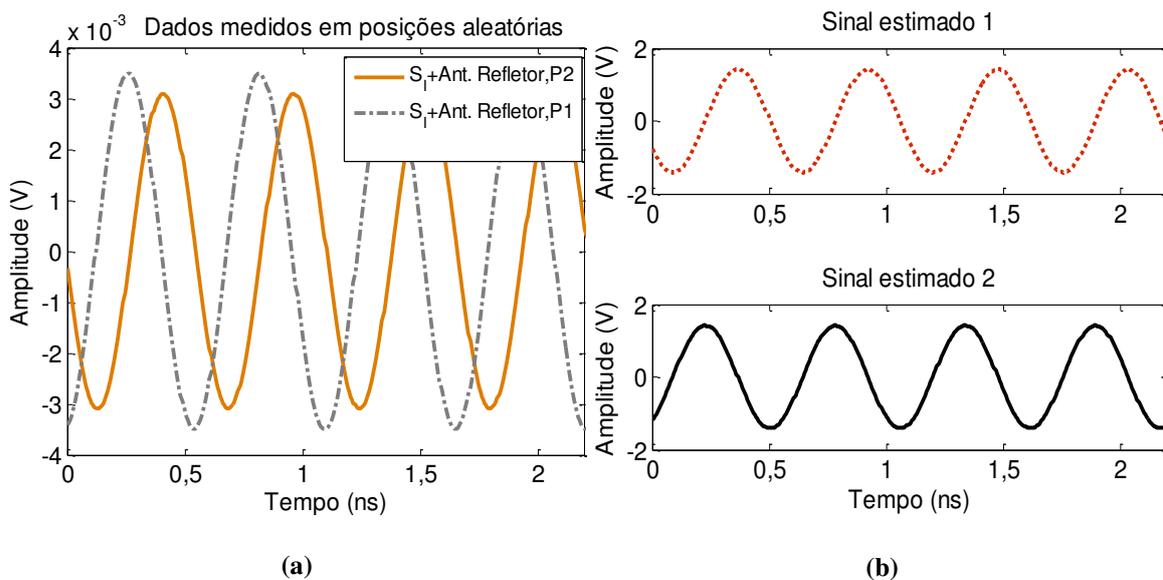


Figura 37 – (a) Sinais medidos nas posições P1 e P2, para antena ativa mais antena dipolo como refletor; (b) Sinais estimados a partir dos dados da Figura 37.a.

Calculando os coeficientes de correlação entre os sinais estimados e o sinal fonte (emitido por S_I), obtêm-se: entre o sinal estimado 1 e S_I , $CoefCorr$

= 0,841 e entre o sinal estimado 2 e S_I , $CoefCorr = -0,541$. Esses valores demonstram que apesar do sinal estimado 2 apresentar comportamento semelhante ao sinal emitido por S_I , eles têm correlação linear moderada, segundo [62]. Isso nos leva a pensar que o coeficiente de correlação pode ser usado como parâmetro de comparação e, a partir do seu valor informar se a componente estimada é referente ao sinal da fonte transmissora ou refere-se à fonte passiva (outra fonte).

Substituindo a antena dipolo, que anteriormente funcionou apenas como elemento passivo, pelo refletor metálico retangular e realizando a medição do sinal emitido por S_I , nas posições P1 e P2, obtêm-se os sinais mostrados a Figura 38.a. Na Figura 38.b, é exposto às componentes independentes (sinais estimados) resultantes da avaliação do ICA, os quais foram obtidos a partir dos dados da Figura 38.a.

Os coeficientes de correlação entre os sinais estimados e o sinal fonte (emitido por S_I – Figura 36), são: entre o sinal estimado 1 e S_I , $-0,992$ e entre o sinal estimado 2 e S_I , $0,127$. Neste caso obteve-se um coeficiente de correlação linear fraco entre o sinal estimado 2 e o sinal emitido por S_I . Isso pode estar associado a múltiplas reflexões que o sinal S_I sofre até chegar à antena receptora após espalhar-se no refletor. Esse fato pode gerar um sinal que tenha pouca similaridade com o sinal original.

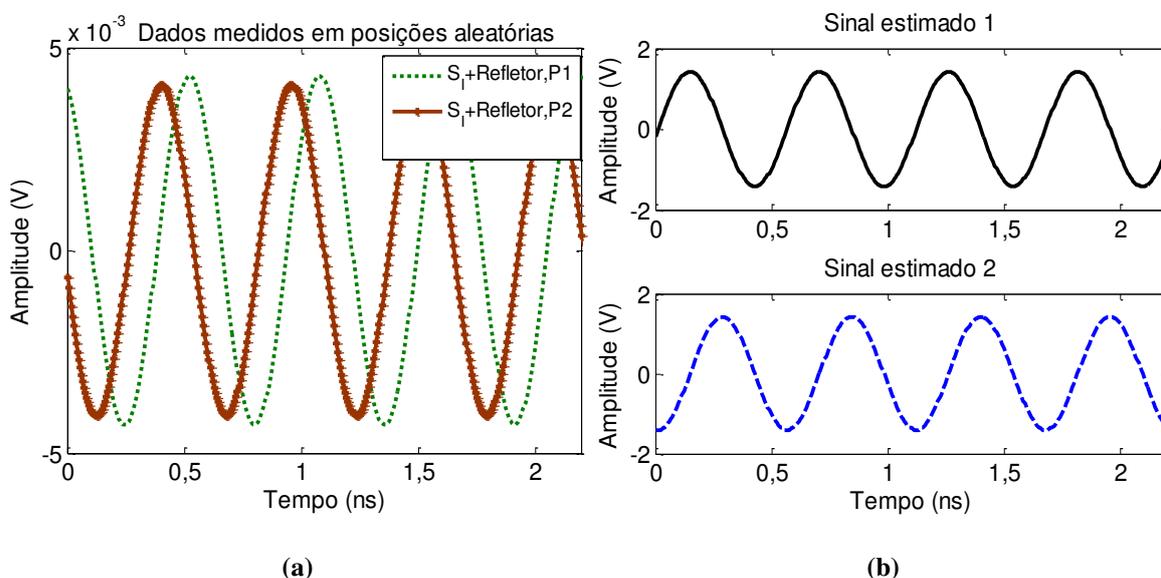


Figura 38 – (a) Sinais medidos nas posições P1 e P2, para antena ativa + refletor retangular; (b) Sinais estimados a partir dos dados da Figura 38.a.

A análise direta das componentes estimadas, nesse experimento, leva a crer que existe outra fonte transmissora além de S_I . Essa fonte pode estar relacionada ao refletor, já que o campo eletromagnético incidente nele é produzido por S_I ou por outra fonte nas proximidades. No caso do refletor isso resulta em outra fonte, que tem relação com o sinal da fonte original. Estabelecendo-se um limiar para o coeficiente de correlação, os resultados indicam que é possível inferir a presença de elementos passivos em torno da antena.

5.6 Experimento 6: Duas Fontes com Frequências Próximas

Neste experimento foi investigado o comportamento do ICA quando se tem duas fontes com frequências próximas. A diferença de frequência entre os sinais foi de apenas 10 MHz, o que corresponde a uma diferença percentual de 0,63%. As fontes originais são compostas por dois geradores de micro-ondas de fabricantes diferentes: gerador vetorial SMBV 100A da *R&S* (9 kHz – 6 GHz) e, gerador de sinais RF N9310A da *Agilent* (9 kHz – 3 GHz). Cada gerador foi conectado a uma antena log-periódica planar (WA5JVB 0,9 – 2,6 GHz) por meio de cabos coaxiais.

As antenas foram excitadas com um sinal senoidal (onda contínua). O valor de potência dos geradores foi ajustado para -5 dBm e frequências: $F_{R\&S} = 1,59$ GHz e $F_{Agilent} = 1,60$ GHz.

5.6.1 Procedimentos de Medição

Os procedimentos e o esquema de medição que serão descritos a seguir foram utilizados nos experimentos 6 e 7 (Seção 5.7). Eles também servem de base para outros ensaios descritos no Capítulo 6. O esquema de medições é ilustrado na Figura 39. Além dos equipamentos citados acima, compõe o esquema de medição: dois cabos coaxiais de mesmo tamanho (1,10 m) e impedância de 50Ω ; um analisador de espectro (*R&S*, FSL6, 9 kHz – 6 GHz); e uma antena log-periódica (*R&S*, HL040, 0,3 – 4 GHz). As antenas

foram dispostas colinearmente a distância de $\lambda_0/2$ (comprimento de onda, no espaço livre, para a frequência de 1,60 GHz) uma da outra.

As distâncias (l_i , $i = 0, 1, 2, 3, 4$) entre as antenas transmissoras e receptoras podem ser escolhidas aleatoriamente assegurando-se que as medições sejam feitas na região de campos distantes. Essas distâncias foram: $l_0 = 2,45$ m, $l_1 = 2,65$ m, $l_2 = 3,50$ m, $l_3 = 2,80$ m e $l_4 = 3,00$ m.

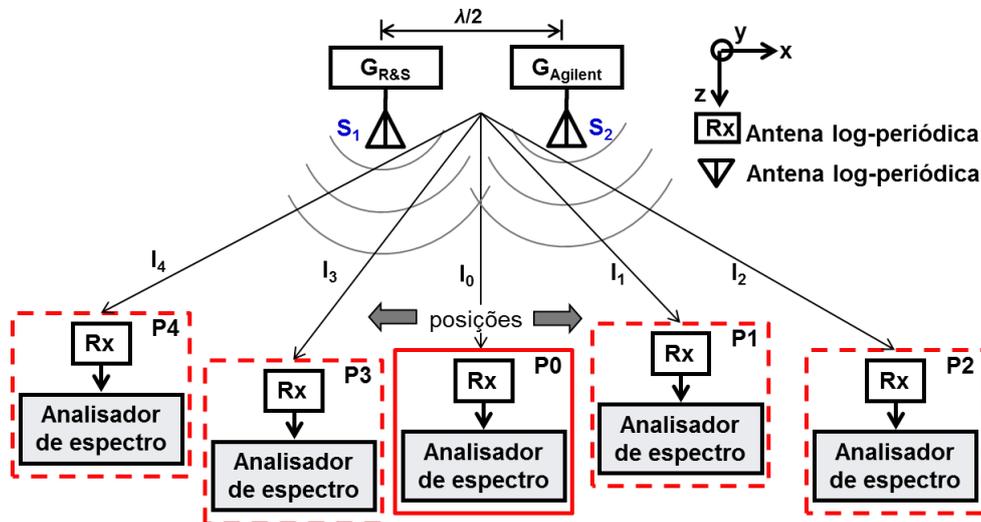


Figura 39 – Esquema ilustrativo para as medições dos experimentos 6 e 7.

Na primeira posição colocou-se a antena Rx no eixo z, perpendicular ao eixo das antenas transmissoras (eixo x), as demais posições de Rx foram deslocadas para a esquerda e direita da posição P0. Os dados foram coletados em escala logarítmica (dBm). O processo de aquisição dos dados seguiram os seguintes procedimentos:

1. Inicialmente mediu-se o ruído ambiente, na posição P0, sem que as antenas S_1 e S_2 estivessem excitadas. O ruído foi considerado como uma fonte de sinal;
2. Depois, cada antena foi excitada, individualmente, com um sinal senoidal (onda contínua) e seu espectro foi medido na posição P0, usando o analisador de espectro. Primeiramente S_1 foi ligada com S_2 retirada da montagem. Depois S_2 foi ligada retirando S_1 da montagem. Esses sinais são tomados como referência para posterior comparação (ver a Figura 40);
3. Em seguida as duas antenas foram excitadas, ao mesmo tempo. Usando o conjunto receptor antena (Rx) mais analisador de espectro, mediu-se o sinal nas cinco posições diferentes: P0, P1, P2, P3 e P4 (Figura 39).

4. Então, os dados medidos nas diferentes posições são aplicados como dados de entrada para o modelo ICA (3.1). Eles preenchem o vetor de misturas \mathbf{x} .

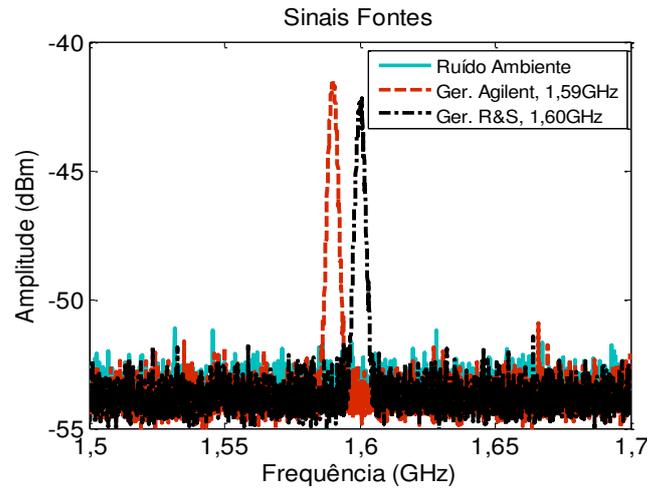


Figura 40 – Sinais fontes, medidos na posição P0.

Observa-se, na Figura 40, a pequena proximidade em frequência, entre os sinais e que a amplitude nas frequências desejadas (1,59 e 1,60 GHz) está bem próxima. Nas demais frequências o nível de sinal está no nível do ruído.

Na Figura 41.a, são apresentados os sinais medidos nas posições P0 – P4, com as duas antenas excitadas ao mesmo tempo. O vetor de medidas aleatórias \mathbf{x} em (3.1) foi preenchido, inicialmente, com apenas três medições (P0, P1 e P2) daquelas vistas na Figura 41.a. O resultado dos sinais estimados, ou seja, das componentes independentes é exposto na Figura 41.b.

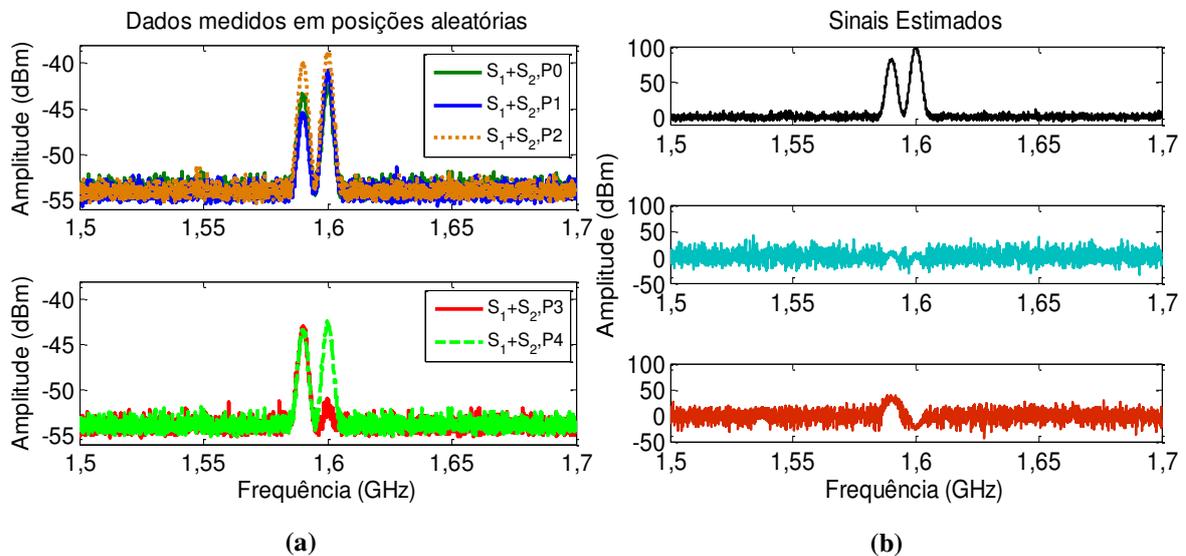


Figura 41 – (a) Sinais misturados medidos nas posições P0 a P4; (b) Sinais estimados a partir dos dados de três medições da Figura 41.a, P0 – P2.

Os gráficos dos sinais estimados, Figura 41.b, foram normalizados da seguinte maneira: procurou-se o valor máximo entre eles, dividiram-se todas as curvas por esse valor e em seguida multiplicou-se todos por 100. Por fim plotou-se os gráficos novamente.

Observa-se que a partir das três medições o ICA recuperou três fontes: o ruído ambiente, uma fonte com duas frequências (1,59 e 1,60 GHz) e outra com o nível bem baixo que se assemelha ao sinal original 1,59 GHz. Portanto, com a proximidade usada entre as frequências, o ICA não conseguiu recuperar, de forma bem clara, as três fontes como esperado para o uso de apenas três posições de medição. Mas, que existe uma forte tendência para separá-los.

Em virtude disso, utilizaram-se os dados de mais uma medição (P3) para preencher o vetor de misturas \mathbf{x} e a esses dados aplicou-se o algoritmo FastICA. Os resultados são apresentados na Figura 42.

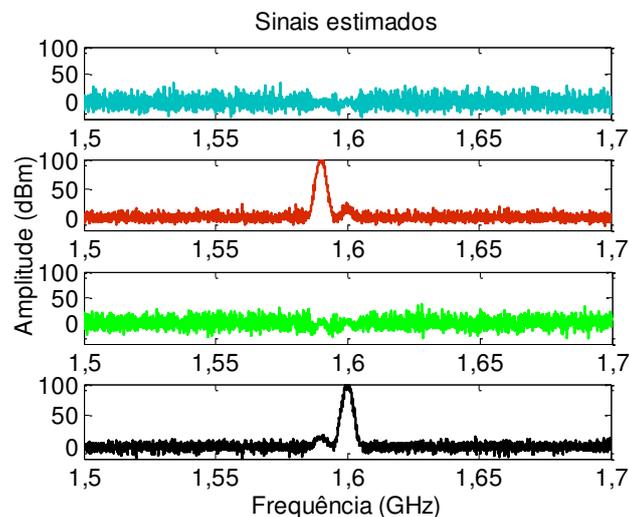


Figura 42 – Sinais estimados a partir de quatro medições, P0 – P3.

Pode-se aferir, agora, que o ICA distinguiu claramente as componentes de frequência das fontes originais (1,59 e 1,60 GHz) e duas fontes, identificadas aqui como ruído. Portanto, o ICA consegue separar e identificar fontes com frequências muito próximas ($\Delta F = 0,63\%$), utilizando-se quatro medições. Essa diferença entre dois sinais senoidais é bem menor do que a diferença conseguida por [10] ($\Delta F = 1,151\%$) e [11] ($\Delta F = 1,425\%$), o que demonstra a potencialidade do ICA em separar sinais com frequências tão próximas.

Teoricamente o modelo usado para o ICA deveria separar as três fontes: ruído ambiente, 1,59 GHz e 1,60 GHz a partir de apenas três medições, mas, na prática, não foi possível, pois os dados medidos produziram mais fontes independentes do que aquelas esperadas (outra fonte de ruído). Assim, acredita-se que se devem ter mais medições para garantir que todas as fontes sejam encontradas. Para confirmar essa ideia aplicou-se o ICA a todos os dados medidos, ou seja, utilizaram-se as cinco medições. Os sinais estimados podem ser vistos na Figura 43.

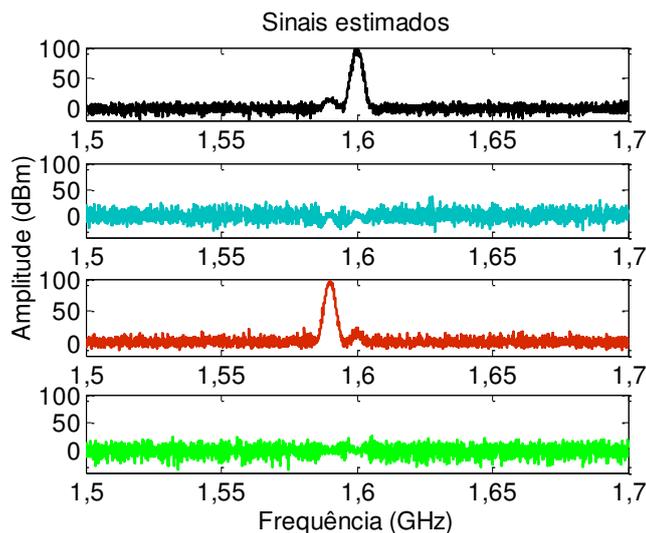


Figura 43 – Sinais estimados a partir de cinco medições, P0 – P4.

Nota-se, na Figura 43, que o ICA encontra o mesmo número de resultados obtidos na situação com apenas quatro medições, ou seja, o ICA reconhece que os dados da quinta medição não são independentes dos demais. Portanto, ele encontra as fontes de $F_1 = 1,59$ GHz, $F_2 = 1,60$ GHz e as duas fontes de ruído. Assim, na prática deve-se fazer, pelo menos, uma medição além daquelas esperadas para o número de fontes. Caso não se tenha ideia do número de fontes, deve-se medir quantas vezes forem necessárias para se encontrar todas as fontes, ou seja, encontrar as fontes desejadas e as demais como sendo ruído. Esse procedimento não seria adequado para situações extremas onde se tenha um número muito elevado de fontes, por exemplo, mil fontes.

Suponha que o número de fontes seja conhecido, por exemplo, se tenha três fontes, por segurança, deve-se medir quatro vezes, aplicar o ICA as

três medições e verificar se todas as três fontes foram encontradas. Caso contrário, utiliza-se a quarta medição e verifica-se se todas as fontes foram estimadas. Se ainda assim não forem encontradas todas as fontes, é possível que o ICA não consiga separá-las. A estratégia é fazer mais medições até que todas as fontes sejam encontradas e as demais sejam apenas fontes de ruído.

Ainda que o procedimento não pareça ser prático é importante lembrar que para casos simples, fontes bem distintas, basta ter o número de sensores igual ao número de fontes. Nos casos especiais, apresentados nessa Seção, um arranjo de 3X3 de antenas *patch* fornece mais de 50 combinações de medição.

5.7 Experimento 7: Duas Fontes com uma das Antenas Inclínada em 45°

Este experimento tem por objetivo verificar se a resposta do ICA sofre influência da polarização das antenas transmissoras. Para esse estudo usamos a mesma montagem vista na Figura 39, com a modificação na posição de uma das antenas (Tx) e na troca do gerador *Agilent* pelo gerador *Rafena* (TYP DMS, 1,50 – 2,72 GHz). O gerador *Rafena* por ser muito antigo (década de 1960) apresenta problemas em manter a frequência sintonizada e o valor de amplitude durante o tempo de realização do ensaio.

Modificou-se a antena S_2 para uma inclinação de 45° em relação ao eixo x . As duas antenas foram alimentadas com um sinal senoidal (onda contínua) de mesma potência (-5 dBm) e com frequências diferentes ($F_{Rafena} = 1,60$ GHz e $F_{R\&S} = 1,61$ GHz). A antena receptora foi posicionada com inclinação de 90° em relação ao eixo x . Na Figura 44 são mostrados a disposição das antenas transmissoras e os sinais capturados na posição P0 quando cada antena é excitada individualmente, conforme os procedimentos descritos na Seção 5.6.1. O nível de sinal recebido na antena receptora (Rx) apresenta valores diferentes em função de uma das antenas está a 45°.

Observação: nos ensaios realizados o intervalo de frequência (1,50 – 1,70 GHz) foi escolhido porque não há fontes EM comerciais funcionando nessa faixa e por se adequar aos equipamentos do laboratório.

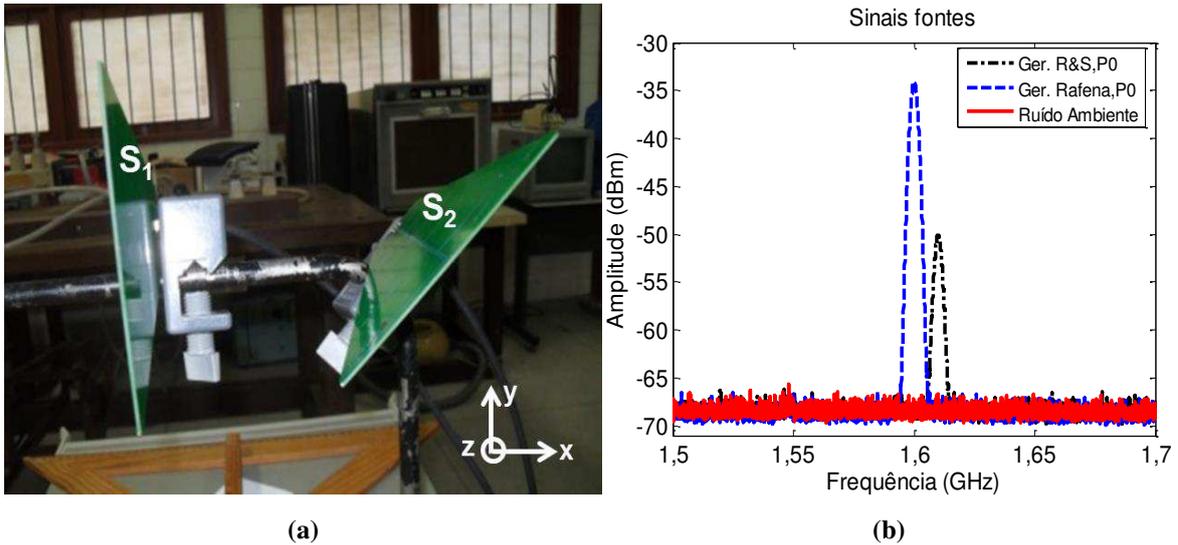


Figura 44 – (a) Disposição das antenas transmissoras, S_1 a 90° e S_2 a 45°, em relação ao eixo x ; (b) Sinais fontes medidos na posição P0.

Observa-se, na Figura 44.b, que o sinal recebido na antena receptora é 15,74 dB menor que aquele transmitido pela antena posicionada na vertical (S_1), co-polarização. Isso acontece porque a antena S_2 não está na mesma polaridade da antena receptora (descasamento de polarização).

Os sinais misturados, obtidos em cinco posições diferentes, são apresentados na Figura 45.

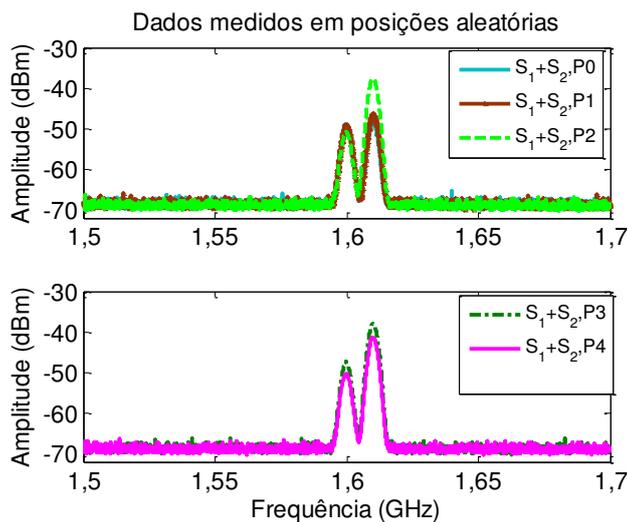


Figura 45 – Sinais medidos em cinco posições diferentes, com as duas antenas excitadas.

Preenchendo o vetor de misturas (\mathbf{x}), de entrada no ICA, com os dados apresentados na Figura 45, encontram-se as componentes independentes. Na Figura 46.a são mostrados os sinais estimados utilizando-se apenas as três primeiras medições (P0 – P2); na Figura 46.b estão os sinais

estimados quando se utilizam quatro medições (P0 – P3) e; na Figura 46.c quando se utilizam as cinco medições (P0 – P4).

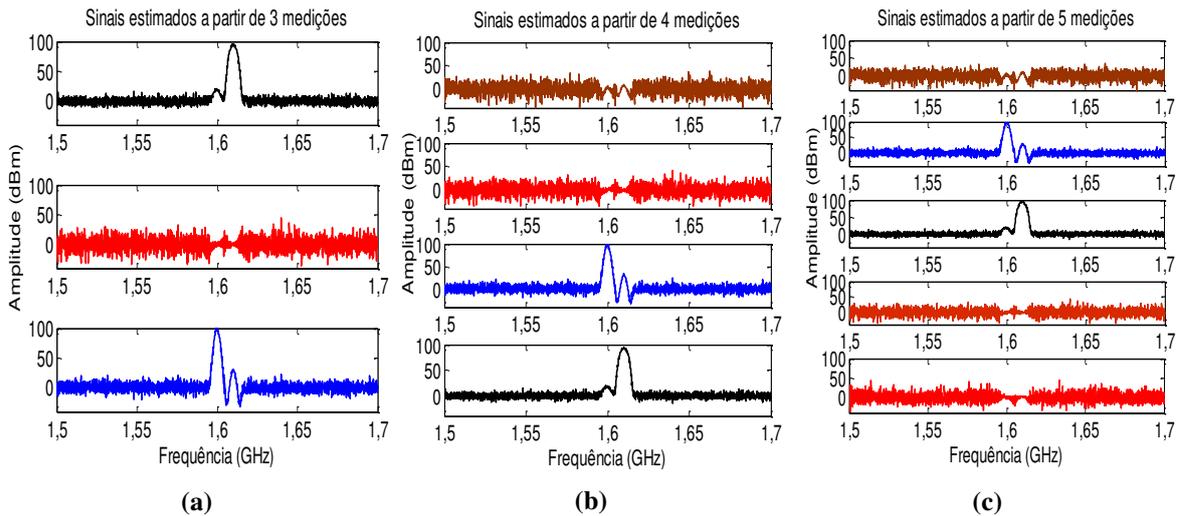


Figura 46 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 45.a, P0 – P2; (b) Sinais estimados a partir dos dados de 4 medições da Figura 45.a, P0 – P3; (c) Sinais estimados a partir dos dados de 5 medições da Figura 45.a, P0 – P4.

Observa-se na Figura 46, que com apenas três medições é possível identificar as fontes desejadas: frequências de 1,60 e 1,61 GHz e o ruído ambiente. No entanto, percebe-se a presença de uma raia ao lado das frequências desejadas, com nível próximo do nível do ruído, como no experimento 6. Isso ocorre devido ao caso especial de proximidade entre as frequências desejadas ($\Delta F = 0,63\%$). Para verificar se há outras fontes EM no intervalo de procura faz-se uso da quarta medição e, em seguida da quinta medição. Como esperado, nota-se nas Figuras 46.b e 46.c, que o ICA separa e identifica apenas outras fontes de ruído quando mais medições são consideradas.

O aumento no número de medições trás outro benefício: uma melhoria nos níveis de amplitude das frequências desejadas e uma redução no nível das raias próximas a essas frequências. Isso torna mais visível a separação e identificação das fontes EM utilizadas no experimento. Aqui, o aumento de amplitude, nas frequências desejadas, é maior quando se utiliza quatro ao invés de três medições (aumento de aproximadamente 6 dB). No entanto, esse aumento não é constante, ele diminui à medida que se aumenta o número de medições. Um aumento do número de medições, de 4 para 5 tem-se um acréscimo de ≈ 1 dB apenas. A redução na amplitude das raias

indesejadas é maior quando se usa quatro ao invés de três medições (redução de ≈ 9 dB) e menor quando se utilizam cinco medições ao invés de quatro (redução ≈ 1 dB). Portanto, em geral, obtém-se uma melhoria na separação e identificação das fontes quando se utilizam mais medições do que fontes até um limite, quando então a contribuição não é significativa.

Os casos em que se têm mais medições do que fontes são denominados de sobre determinados [25]. Nessa situação têm-se um número maior de informações (medições ou misturas) que amplia o espaço de busca do modelo do ICA. Isso facilita o processo de separação e identificação das fontes.

O fato de se ter uma das antenas com polaridade diferente da receptora não provocou grandes mudanças na resposta do ICA, ou seja, o ICA consegue separar as fontes EM independentemente da polarização das antenas transmissoras e receptoras.

O uso do gerador *Rafena*, de alguma forma produziu mais dados estatisticamente independentes que levaram o ICA a identificar mais fontes de ruído do que aquela prevista e o aparecimento de outras raias.

Resultados idênticos são obtidos caso os níveis de sinal, capturados pela antena receptora tenham os mesmos valores, ou seja, se a potência do gerador que alimenta a antena S_2 for, propositalmente, aumentada de forma que na recepção (Rx) se capture o mesmo nível de sinal emitido por S_1 , o ICA conseguirá separar as duas fontes desejadas e o ruído, independentemente da amplitude e da polarização das antenas.

5.8 Conclusão do Capítulo

Neste Capítulo foi descrito uma série de experimentos que buscaram avaliar o ICA em diversas situações, principalmente quando se tinha fontes excitadas igualmente, com pouca diferença em frequência, com polaridades diferentes e especialmente muito próximas.

Os elevados valores do coeficiente de correlação indicam uma boa precisão do método ICA e que ele é capaz de separar duas fontes com pequenas diferenças de fase, com mesma amplitude e frequência a partir das

informações de fase e amplitude dos sinais medidos em posições aleatórias, mesmo estas estando muito próximas ($d \ll \lambda_0$).

As modificações nos procedimentos de coleta de dados para aplicação do ICA, no caso de se ter fontes idênticas e muito próximas, demonstraram ser determinantes para resolver esse caso que se mostrou, a princípio, sem solução. A medição apenas do espectro de amplitude não é suficiente para a identificação das fontes.

Quando se tem apenas duas fontes com frequências diferentes ($F_{TX1} = 1,837$ GHz e $F_{TX2} = 1,800$ GHz), mas a distância é fisicamente próxima ($d = \lambda_0/4$), o ICA é capaz de separá-las. Nessa situação é suficiente medir apenas o espectro de amplitude dos sinais transmitidos (sinais fontes).

Estejam às fontes dispostas uma atrás da outra ou lado a lado o ICA pode ser aplicado para obter a separação, mesmo nos casos em que a distância entre as fontes é muito pequena ($d \ll \lambda_0$). Situação comum em problemas de determinação da DoA.

A orientação espacial da antena receptora (45° ou 90° em relação ao eixo x) e sua distância as fontes não afetam a resposta do ICA.

Uma característica do ICA é garantir a separação dos sinais e para isso a sua fórmula matemática impõe uma defasagem fixa de 90° o que resulta em uma perda da identificação da fase entre os sinais estimados em relação aos sinais originais.

O coeficiente de correlação se mostrou eficaz na determinação da presença de elementos passivos em torno da antena.

Pode-se concluir que no caso de duas fontes de sinais senoidais com frequências próximas ($\Delta F = 0,63\%$) o ICA consegue separá-las e identificá-las utilizando-se três medições. A precisão aumenta com o uso de uma quarta medição. Sugere-se, na prática fazer, pelo menos, uma medição além daquelas esperadas para um determinado número de fontes. Caso o número de fontes não seja conhecido, deve-se fazer quantas medições forem necessárias para obter as fontes desejadas e pelo menos uma fonte de ruído.

Um número maior de medições permite uma melhoria na resolução dos sinais estimados (aumento na amplitude do sinal desejado e redução na

amplitude das raias indesejadas). Portanto, em geral, obtém-se uma melhoria na separação e identificação das fontes quando se utilizam mais medições do que fontes.

A resposta do ICA não é influenciada pela possível diferença de polarização linear que os sinais possam sofrer. Conseguiu-se separar e identificar fontes que apresentam proximidade de frequências e polarização diferente.

Capítulo 6

6. Aplicação do ICA para Separação de Múltiplas Fontes Irradiantes

Neste Capítulo serão expostos vários experimentos de separação e identificação de múltiplas fontes eletromagnéticas (EM) irradiantes usando o método ICA. O objetivo é aplicar e verificar se o ICA é capaz de separar múltiplas fontes senoidais que apresentam valores de ΔF desde pequenos a grandes. As fontes serão produzidas por geradores de micro-ondas ou por rádio definido por *software* (RDS). Também são mostrados experimentos que visam à utilização do ICA para o sensoriamento do espectro de rádio frequência. Em particular o caso de sinais de banda larga com largura de faixa de 6 MHz e de fontes de sinais FM. Neste Capítulo é exibido o valor mínimo de diferença em frequência ΔF entre dois sinais senoidais capaz de ser separado e identificado usando o ICA.

Na Seção 6.1 é descrito o ensaio com três fontes produzidas por geradores de micro-ondas conectados a antenas log-periódicas dispostas colinaramente. A Subseção 6.1.3 apresenta experimentos sobre a separação de fontes com baixa relação sinal-ruído e pequeno ΔF . A Seção 6.2 traz os ensaios com fontes produzidas por rádio definido por *software* (RDS). São apresentadas as situações em que a fonte apresenta múltiplas frequências indesejáveis e ΔF grande e pequeno. Na Seção 6.3 é discutida a proposta de usar o ICA para sensoriamento espectral para utilização em rádio cognitivo. Para tal são expostos os ensaios com sinais provenientes dos canais de TV aberta (analógica e digital). A Seção 6.4 trata da separação de sinais FM com portadoras idênticas e diferentes. A análise é realizada em dados obtidos em simulação e medidos. O Capítulo é encerrado com as conclusões na Seção 6.5.

Nos experimentos com sinais produzidos com gerador de micro-ondas e RDS foram usadas como fontes transmissoras três antenas log-

periódicas planares (WA5VJB) projetadas para operar na faixa de 0,9 – 2,6 GHz. Nos experimentos com canais de TV foram usados os sinais transmitidos por duas emissoras de TV local (cidade de Campina Grande – PB) e um gerador de sinais. A recepção dos sinais foi realizada usando uma antena log-periódica conectada a um analisador de espectro. As medições foram realizadas no ambiente do LEMA (Laboratório de Eletromagnetismo Aplicados) e do LAPS (Laboratório de Processamento de Sinais), localizados na UFCG, *campus* – Campina Grande.

6.1 Fontes Produzidas por Geradores de Micro-Ondas

Nesta Seção serão apresentados cinco ensaios com fontes EM senoidais (*CW – continuous wave*) em situações diferentes para ΔF . Todos os sinais utilizados aqui foram produzidos por geradores de micro-ondas, de fabricantes diferentes, operando na faixa de 1,00 – 1,70 GHz. Essa faixa de frequência foi escolhida por não ter fontes EM comerciais e melhor se adequar aos equipamentos (geradores, antenas e analisador de espectro) disponíveis nos laboratórios. Os coeficientes de reflexão (S_{11}), das antenas transmissoras, são apresentados no anexo A.

6.1.1. Fontes com Frequências muito Distintas

Com o objetivo de avaliar a capacidade do ICA na separação de múltiplas fontes foi, inicialmente, realizado um ensaio com três fontes EM com frequências muito distintas ($\Delta F = 14,28\%$). Para isso, utilizou-se o esquema de medição exibido na Figura 47. As distâncias l_i entre as antenas transmissora e receptora foram: $l_0 = 2,2$ m, $l_1 = 2,8$ m, $l_2 = 2,7$ m, $l_3 = 3,2$ m e $l_4 = 3,4$ m.

O esquema de medição é composto por três antenas transmissoras log-periódicas planares, (WA5JVB, 0,90 – 2,60 GHz), ligadas a três geradores de micro-ondas (*R&S*, SMBV 100A, 9 kHz – 6 GHz; *Agilent*, RF N9310A, 9 kHz – 3 GHz e, *Rafena* TYP DMS, 1,50 – 2,72 GHz). Esse conjunto forma as fontes transmissoras (S_I , S_{II} e S_{III}). O valor de potência dos geradores foi ajustado para -5 dBm e frequências: $F_{R\&S} = 1,20$ GHz; $F_{Agilent} = 1,40$ GHz e

$F_{Rafena} = 1,60$ GHz. Na recepção usou-se uma antena log-periódica de alto ganho e banda larga (Rx) (A.H Systems SAS 510-7, 0,29 – 7,00 GHz). As conexões são feitas com cabos coaxiais de 50Ω e 1,10 m de comprimento. As medições nas posições P0, P1, P2, P3 e P4 foram feitas usando um analisador de espectro da R&S, modelo FSL6 (9 kHz – 6 GHz), operando na faixa de 1,0 – 1,7 GHz.

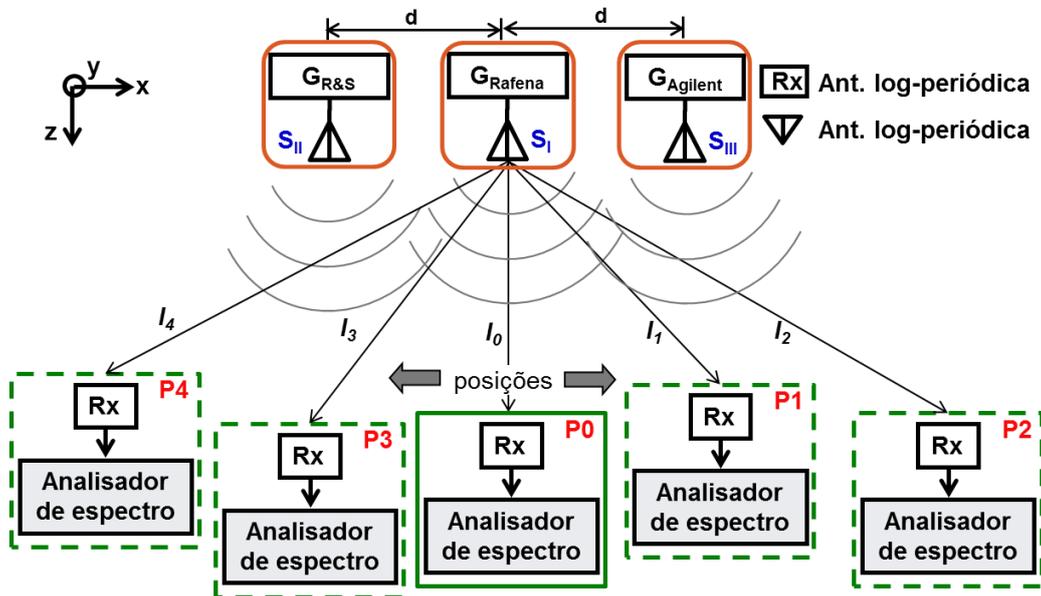


Figura 47 – Esquema de medição para os ensaios com múltiplas fontes.

Os procedimentos de medição descritos na Subseção 5.6.1 também foram aplicados neste experimento, acrescentando-se a etapa de medir isoladamente o sinal da terceira fonte (S_{III}). Os sinais fontes originais são expostos na Figura 48. Todos foram medidos na posição P0.

Observa-se, na Figura 48, que o nível de sinal para a frequência de 1,60 GHz é inferior aos fornecidos pelos outros geradores, isto acontece porque o gerador *Rafena* não mantém estável o nível de sinal gerado. Durante o ensaio, observou-se também, que mesmo desconectando a antena do gerador *Rafena* pode-se medir sinal na frequência de 1,60 GHz proveniente do cabo de conexão. Para minimizar o nível do sinal emitido pelo cabo, o envolvemos em material absolvevente no conector (indisponibilidade de uma carga de 50Ω para o cabo). Ainda assim foi possível captar um pequeno nível de sinal nos gráficos das outras frequências (1,20 GHz, 1,40 GHz e do ruído).

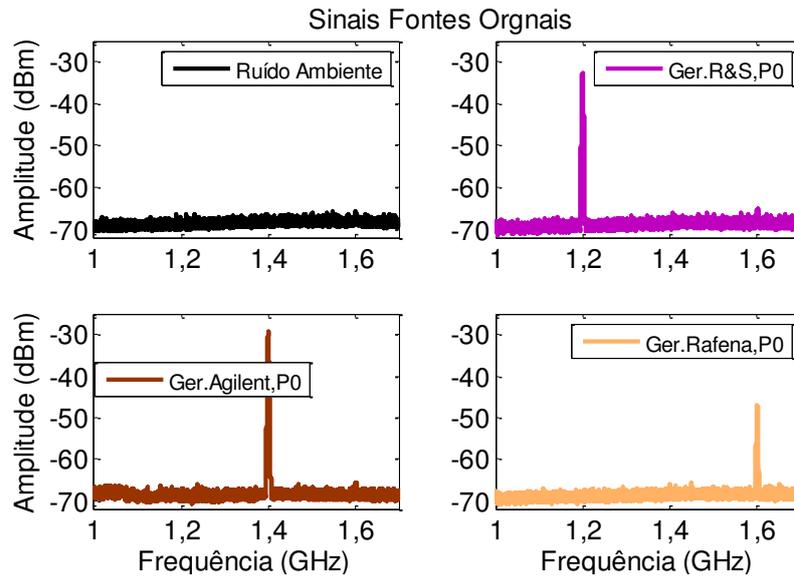


Figura 48 – Fontes originais, ruído ambiente, 1,20, 1,40 e 1,60 GHz, respectivamente.

Os sinais que serão submetidos ao ICA, para separação e identificação, são mostrados na Figura 49. A medição, em cada posição vista na Figura 47, é composta pelas contribuições de cada sinal emitido pelas três antenas simultaneamente (sinais misturados). Como esperado os níveis de amplitude, em cada posição de medição são diferentes.

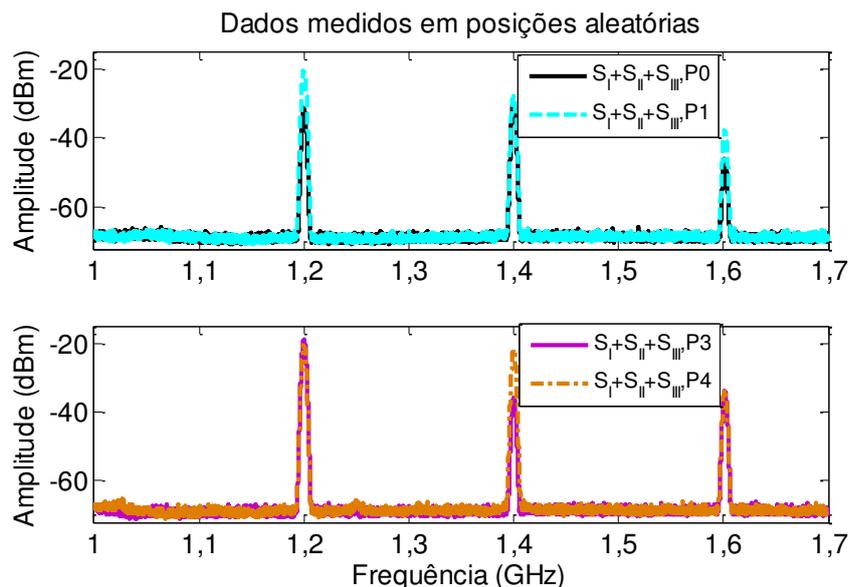


Figura 49 – Sinais misturados, medidos em cinco posições diferentes.

Os sinais estimados (componentes independentes), utilizando-se as quatro primeiras medições são mostrados na Figura 50.a. Quando se utiliza as cinco medições o resultado das componentes independentes são aqueles mostrados na Figura 50.b.

Observação: o fato de se utilizar sequencialmente as primeiras quatro medições (P0 – P3) não é determinante para uma melhor ou pior qualidade na separação das fontes pelo ICA. Poder-se-ia usar qualquer sequência de medição.

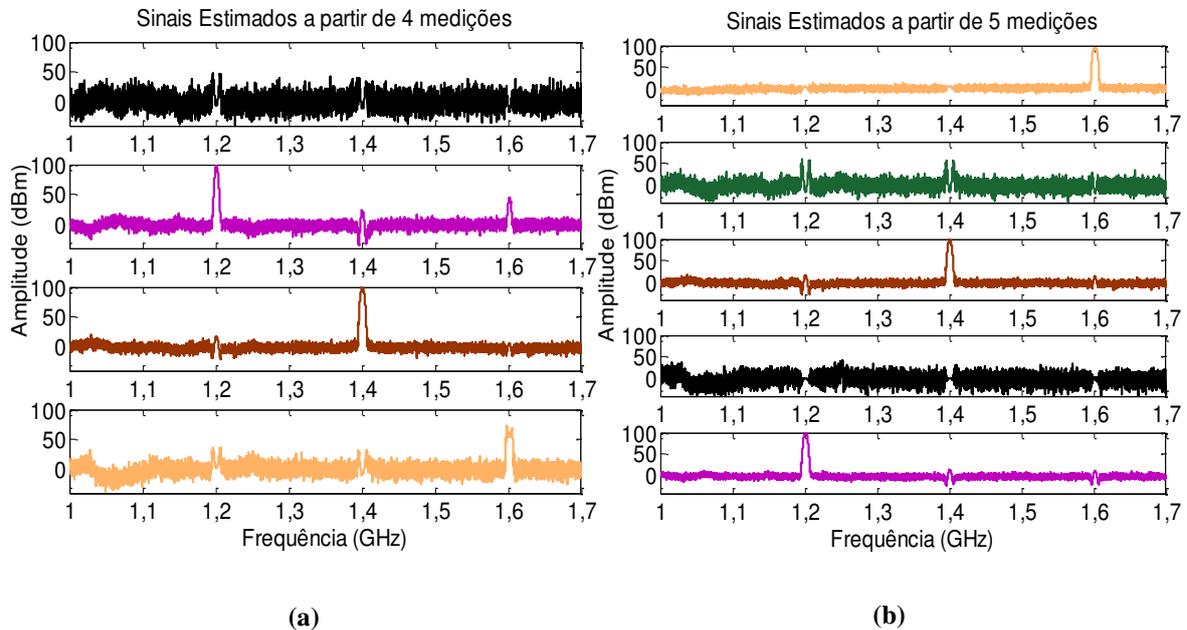


Figura 50 – (a) Sinais estimados, usando 4 medições dos dados da Figura 49; (b) Sinais estimados, usando 5 medições dos dados da Figura 49.

Observa-se, na Figura 50, que o ruído e as frequências de 1,20, 1,40 e 1,60 GHz foram recuperadas e que não há outras fontes além de ruído (Figura 50.b). No gráfico da componente 1,20 GHz (Figura 50.a), também aparece à frequência de 1,60 GHz que existe no sinal original (Figura 48), só que aqui ela aparece mais destacada. A componente de 1,60 GHz aparece com comportamento diferente do sinal original. Isso está ligado ao fato de que não se tem total controle sobre a precisão da amplitude e frequência geradas pelo gerador *Rafena*. O que pode estar gerando mais informações estatisticamente independentes do que aquelas esperadas.

Observando os resultados dos sinais estimados (Figura 50) nota-se que o ICA é capaz de separar claramente as múltiplas fontes EM irradiantes, tendo elas frequências e amplitudes distintas, e independentemente da combinação dos dados de medição.

6.1.2. Fontes com Frequências muito Próximas

Após os ensaios realizados até aqui, observou-se que o ICA pode separar duas ou mais fontes com frequências bem diferentes ($\Delta F = 14,28\%$). O passo seguinte é determinar a menor diferença ΔF que o ICA pode distinguir dois sinais. Para tal foram realizadas simulações com dois sinais senoidais, com as características a seguir:

- Gerou-se os sinais fontes: $s_1 = \text{sen}(2\pi f_1 t)$ e $s_2 = \text{sen}(2\pi f_2 t)$;
- Fixou-se f_1 em 1,8 GHz e variou-se f_2 em valores percentuais de f_1 , ou seja, $f_2 = f_1 + \Delta f_1$;
- Calculou-se a FFT dos sinais s_1 e s_2 ;
- Misturaram-se, aleatoriamente, os sinais resultantes da FFT;
- Aplicou-se o ICA aos sinais misturados;
- Observaram-se as frequências estimadas, com precisão de até nove casas decimais e não apenas quatro casas, como antes;
- Calculou-se o coeficiente de correlação entre as componentes estimadas (CI_1 e CI_2) e os sinais originais (s_1 e s_2).

Teoricamente o ICA consegue separar sinais com frequências iguais, desde que eles sejam estatisticamente independentes. Porém, numericamente encontrou-se um limite para dois sinais senoidais, estatisticamente independentes, com frequências muito próximas. O limite encontrado refere-se à versão do algoritmo FastICA (disponível em [68]) usada neste trabalho.

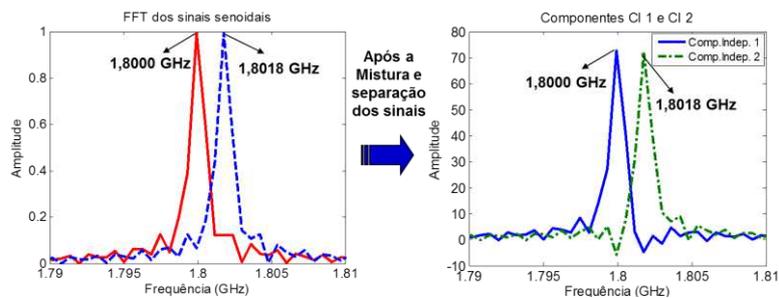
Na Tabela 4, são apresentados os valores de frequência; a diferença percentual entre as frequências originais e recuperadas; os valores de frequência que foram estimadas pelo ICA; se houve ou não separação e identificação e; os coeficientes de correlação entre os sinais originais (s_1 e s_2) e as componentes independentes (CI_1 e CI_2).

Na Figura 51, é mostrado um exemplo de como se comportam os sinais fontes e as componentes independentes quando a diferença de frequência entre os sinais é de 0,10% ($f_1 = 1,8000$ e $f_2 = 1,8018$ GHz) e de 0,05% ($f_1 = 1,8000$ e $f_2 = 1,8009$ GHz).

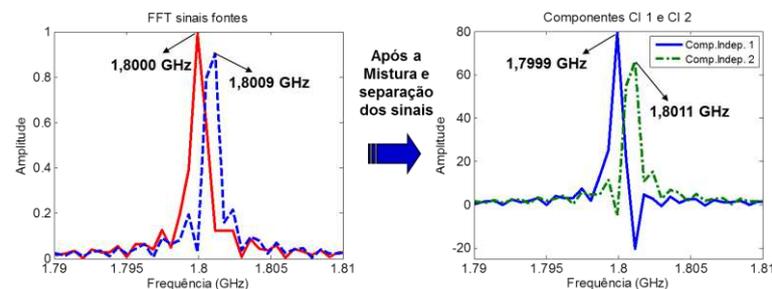
Tabela 4 - Valores usados para determinar o limite numérico da diferença em frequência entre os sinais que o ICA consegue separar.

Frequências originais (Hz)			Frequências recuperadas (Hz)			Estatos	Coeficientes de correlação			
f_1	f_2	ΔF (%)	f_{1rec}	f_{2rec}	ΔF_{rec} (%)		$s_1 \times CI_1$	$s_1 \times CI_2$	$s_2 \times CI_1$	$s_2 \times CI_2$
1.800.000.000	1.809.000.000	0,500000	1.809.082.031	1.799.926.758	0,508647	Separa e Identifica	0,99886	0,04783	0,04675	0,99891
1.800.000.000	1.801.800.000	0,100000	1.801.757.813	1.799.926.758	0,101729		0,98220	0,18786	0,14332	0,98968
1.800.000.000	1.801.620.000	0,090000	1.801.757.812	1.799.926.758	0,101729		0,98758	0,15715	0,17225	0,98505
1.800.000.000	1.801.260.000	0,070000	1.801.147.461	1.799.926.758	0,067820		0,98571	0,16846	0,27203	0,96229
1.800.000.000	1.801.080.000	0,060000	1.801.147.461	1.799.926.758	0,067820	Separa	0,96992	0,24343	0,26187	0,96510
1.800.000.000	1.800.900.000	0,050000	1.801.147.461	1.799.926.758	0,067820		0,90975	0,41516	0,08961	0,99598
⋮	⋮	⋮	⋮	⋮	⋮		⋮	⋮	⋮	⋮
1.800.000.000	1.800.018.000	0,001000	1.799.804.688	1.799.987.793	0,050872		0,91999	0,38680	0,91982	0,38721
1.800.000.000	1.800.001.800	0,000100	1.800.415.039	1.800.170.898	0,067744		0,91250	0,40523	0,91232	0,40564
⋮	⋮	⋮	⋮	⋮	⋮		⋮	⋮	⋮	⋮
1.800.000.000	1.800.000.250	0,000014	1.800.170.898	1.800.354.003	0,0508211		0,93947	0,33867	0,93932	0,33910
1.800.000.000	1.800.000.220	0,000012	1.800.000.000	***	***	Não Separa	1,00000	0,00000	***	***
1.800.000.000	1.800.000.200	0,000010	1.800.000.000	***	***		1,00000	0,00000	***	***
⋮	⋮	⋮	⋮	⋮	⋮		⋮	⋮	⋮	⋮
1.800.000.000	1.800.000.000	0,000000	1.800.000.000	***	***		1,00000	0,00000	***	***

*** o ICA interpreta que há apenas um sinal.



(a) Sinais fontes com $\Delta F = 0,10\%$ e sinais estimados, respectivamente.



(b) Sinais fontes com $\Delta F = 0,05\%$ e sinais estimados, respectivamente.

Figura 51 – Exemplo ilustrativo do processo de determinação do limite de frequência entre dois sinais que o ICA pode separar e identificar.

Como pode ser visto na Figura 51 e na Tabela 4, quando a diferença em frequência é muito pequena ocorre pequenos erros nos valores de frequência estimados pelo ICA, mas ainda assim é possível separar os sinais

originais. Quando essa diferença chega a menos de 0,07% o algoritmo FasICA não consegue mais separar e identificar os sinais fontes. Ocorre separação, mas a identificação fica comprometida, porque não é possível distinguir se as componentes obtidas referem-se à frequência da fonte s_1 ou à frequência da fonte s_2 . Provavelmente o problema está relacionado à precisão do algoritmo implementado em *Matlab*. Com $\Delta F < 0,07\%$ há a repetição de quatro valores de frequências: 1.799.926.758 e 1.800.537.109 ou 1.802.978.516 e 1.799.316.406, independentemente se a diferença é de 0,006% ou 0,000014% (aproximadamente 250 Hz). Isso acontece para qualquer uma das funções custo, independentemente se é usado o FastICA com ortogonalização simétrica ou deflação. Para diferenças menores que 0,000014% não se têm mais separação. Portanto, o limite da diferença (numérica) em frequência, em que se têm separação e identificação das fontes, por parte do FastICA, é $\Delta F = 0,07\%$.

Buscando uma comprovação prática do limite numérico, realizou-se um ensaio com três fontes, cuja diferença em frequência foi de apenas $\Delta F = 0,07\%$. Devido a limitações nos equipamentos usados no laboratório, não foi possível realizar ensaios com diferenças de frequência menores que o citado anteriormente.

O esquema montado para medição é apresentado na Figura 47. Os procedimentos de medição foram os mesmos utilizados na Subseção 6.1.1.

As antenas foram excitadas com um sinal CW, com valores de amplitudes próximas e frequências: $F_{R\&S} = 1,60112$ GHz; $F_{Agilent} = 1,59880$ GHz e $F_{Rafena} = 1,60000$ GHz. O valor de 1,60000 GHz foi tomado como referência para calcular os outros valores ($1,60112 = 1,60000 + 0,07\%$ e $1,5988 = 1,60000 - 0,07\%$), diferença de $\pm 1,2$ MHz. As antenas foram dispostas colinearmente à distância $d = \lambda_0/2$ (comprimento de onda para a frequência de 1,60000 GHz), uma da outra. Os sinais fontes são mostrados na Figura 52. Lembrar que esses sinais foram obtidos um de cada vez, ou seja, o gerador *R&S* ligado, os demais desligados; depois o gerador *Agilent* ligado, os demais desligados e assim por diante.

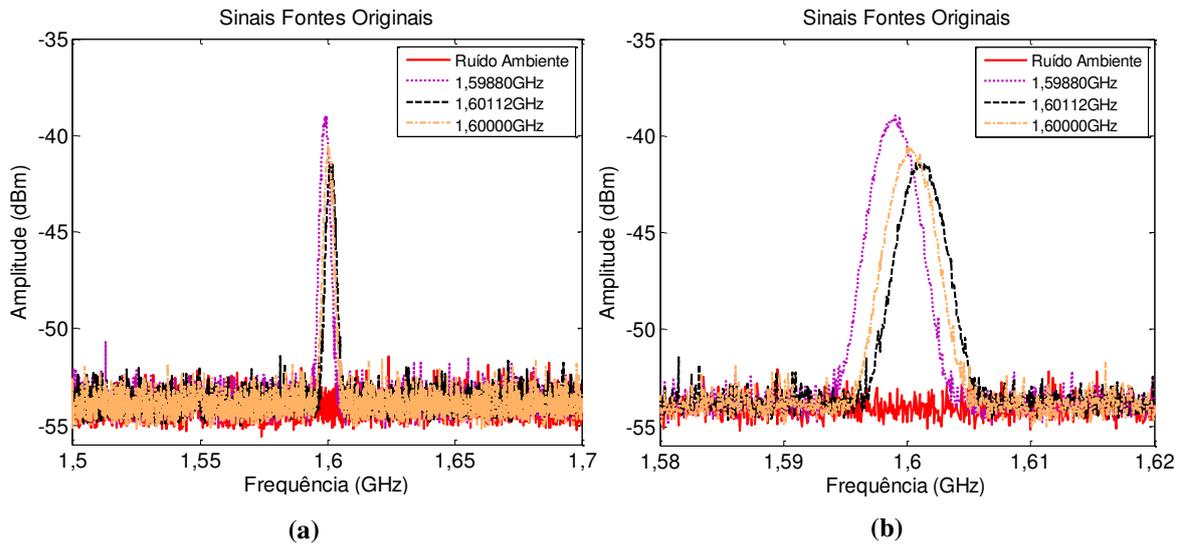


Figura 52 – (a) Sinais fontes com $\Delta F = 0,07\%$; (b) Destaque entre as raiais dos sinais fontes.

Observam-se, na Figura 52, que o nível de sinal não é igual para os três geradores e que as raiais são muitíssimo próximas, dificultado até a visualização e distinção das mesmas. Elas chegam a se sobreporem entre o seu início e término.

Os sinais misturados, ou seja, as contribuições das três antenas excitadas ao mesmo tempo, foram medidas em seis posições distintas, em torno das fontes e são apresentadas na Figura 53.

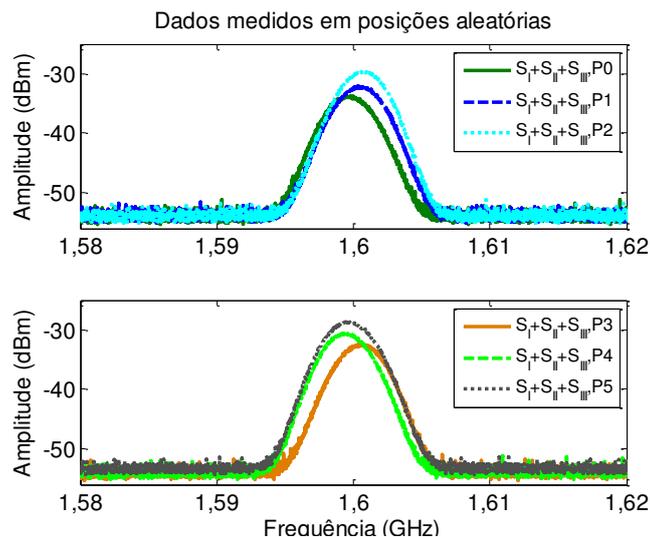


Figura 53 – Sinais medidos em 6 posições diferentes com todas as antenas excitadas.

Aplicando-se o ICA as quatro primeiras medições (P0 – P3) na Figura 53, obtêm-se as componentes independentes mostradas na Figura 54.a; quando se utiliza cinco (P0 – P4) e seis (P0 – P5) medições, respectivamente, obtêm-se as componentes independentes mostradas na Figura 54.b e 54.c.

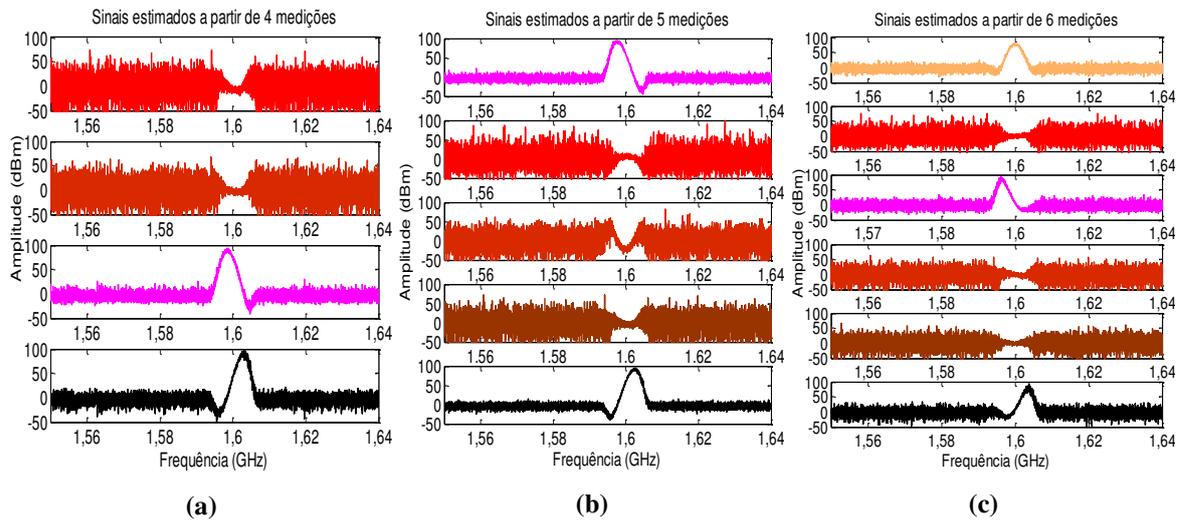


Figura 54 – (a) Sinais estimados a partir dos dados de 4 medições da Figura 53, P0 – P3; (b) Sinais estimados a partir dos dados de 5 medições da Figura 53, P0 – P4; (c) Sinais estimados a partir dos dados de 6 medições da Figura 53, P0 – P5.

O erro relativo entre as frequências estimadas (componentes independentes) e as frequências dos sinais originais é exposto nas Tabelas 5, 6 e 7 para os casos em que se utilizou 4, 5 e 6 medições, respectivamente.

Tabela 5 - Erro obtido para o caso em que se utilizou 4 medições (Figura 54.a)

Frequência original	Frequência estimada	Erro relativo (%)
1,59880	1,59835	0,0279
1,60000	Não recuperou	100
1,60112	1,60309	0,1234

Tabela 6 - Erro obtido para o caso em que se utilizou 5 medições (Figura 54.b)

Frequência original	Frequência estimada	Erro relativo (%)
1,59880	1,59739	0,0885
1,60000	Não recuperou	100
1,60112	1,60229	0,0728

Tabela 7 - Erro obtido para o caso em que se utilizou 6 medições (Figura 54.c)

Frequência original	Frequência estimada	Erro relativo (%)
1,59880	1,59617	0,1648
1,60000	1,59963	0,0234
1,60112	1,60389	0,1733

Conforme pode ser observado na Figura 54, o ICA não conseguiu recuperar as fontes previstas quando se utilizou quatro e cinco medições. Porém, utilizando-se mais uma medição o algoritmo conseguiu identificar as

três fontes desejadas existentes e as demais como ruído. Portanto, a resposta do ICA ficou comprometida devido a grande proximidade entre as frequências (0,07%) dos sinais fontes. Na prática exigiram-se mais medições do que o esperado na teoria. Os erros entre as frequências desejadas e as estimadas foram relativamente pequenos. No pior caso o erro (em que houve separação) foi menor do que 0,18%. O limite numérico do algoritmo FastICA, só foi atingido com êxito, na prática, fazendo uso de mais medições do que fontes.

Acredita-se que os problemas de precisão, conexão e configuração dos equipamentos usados no ensaio tenham contribuído no comprometimento de coleta dos dados. Em consequência disso tenha provocado a não separação dos sinais por parte do ICA, mesmo os sinais sendo tão próximos. Uma solução a ser testada poderia ser modificar os parâmetros do analisador de espectro (largura de faixa de resolução (RBW, usou-se 3 MHz), o número de pontos de varredura (*Sweep Point*, usou-se 501) e a largura de faixa de vídeo (VBW, usou-se 10 MHz)) para que a distância de amostragem seja a menor possível.

6.1.3. Fontes com Frequências Próximas

Para aplicar o ICA a outras situações de iteração entre múltiplas fontes decidiu-se optar por sinais com frequências que se diferenciam de 0,63%. Assim, evita-se o problema de se estar trabalhando no limite de separação do ICA e preservam-se os casos de interesse de estudo que são sinais com frequências relativamente próximas.

As características dos sinais fontes originais usados nesse ensaio são: sinais onda contínua muito próximas (ver Figura 55.a) e frequências $F_{\text{Rafena}} = 1,60 \text{ GHz}$, $F_{\text{R\&S}} = 1,61 \text{ GHz}$ e $F_{\text{Agilent}} = 1,59 \text{ GHz}$. Os procedimentos de medição descritos na Subseção 5.6.1 e o esquema de montagem visto na Figura 47 também foram aplicados nesse experimento, acrescentando-se a etapa de medir isoladamente o sinal da terceira fonte (S_{III}). Lembrado que os sinais servirão apenas de referência para comparar se os sinais estimados encontram-se próximos dos sinais transmitidos. As antenas foram dispostas colinearmente a distância de $\lambda_0/2$ (meio comprimento de onda em 1,60 GHz),

uma da outra. Os sinais misturados, obtidos com todas as fontes excitadas, são apresentados na Figura 55.b.

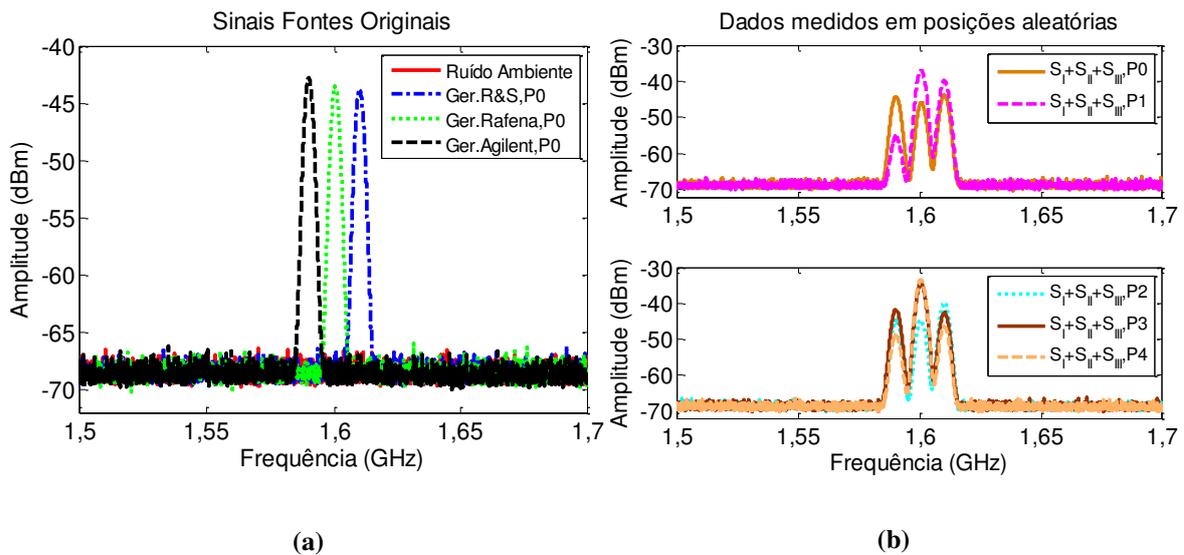


Figura 55 – (a) 3 Sinais fontes com $\Delta F = 0,63\%$ e amplitudes próximas; (b) Sinais medidos em 5 posições, com todas as fontes excitadas.

Os níveis de sinal recebidos na posição P0, para cada gerador (*Agilent*, *Rafena*, *R&S*), são respectivamente: $-42,76$ dBm, $-43,57$ dBm e $-43,81$ dBm. O gerador *Rafena* apresenta potência intermediária em relação aos demais, porém, apresenta oscilações durante o ensaio e variações na frequência (na “ordem” de MHz e kHz) não perceptíveis no espectro fornecido pelo analisador. Essa informação foi observada usando um frequencímetro digital (modelo: HP 5350 B), diretamente conectado ao gerador.

Observando diretamente os gráficos da Figura 55.b poderíamos ser induzidos a pensar que o sinal trata-se de um único sinal. Mas, como será mostrado, têm-se três fontes independentes e com frequências diferentes. Essa é uma vantagem do ICA em relação à FFT, por exemplo.

Aplicando-se o ICA as quatro primeiras medições (P0 – P3) obtêm-se as componentes independentes mostradas na Figura 56.a; quando se utiliza cinco (P0 – P4) e seis (P0 – P5) medições, respectivamente, obtêm-se as componentes independentes mostradas na Figura 56.b e 57.c.

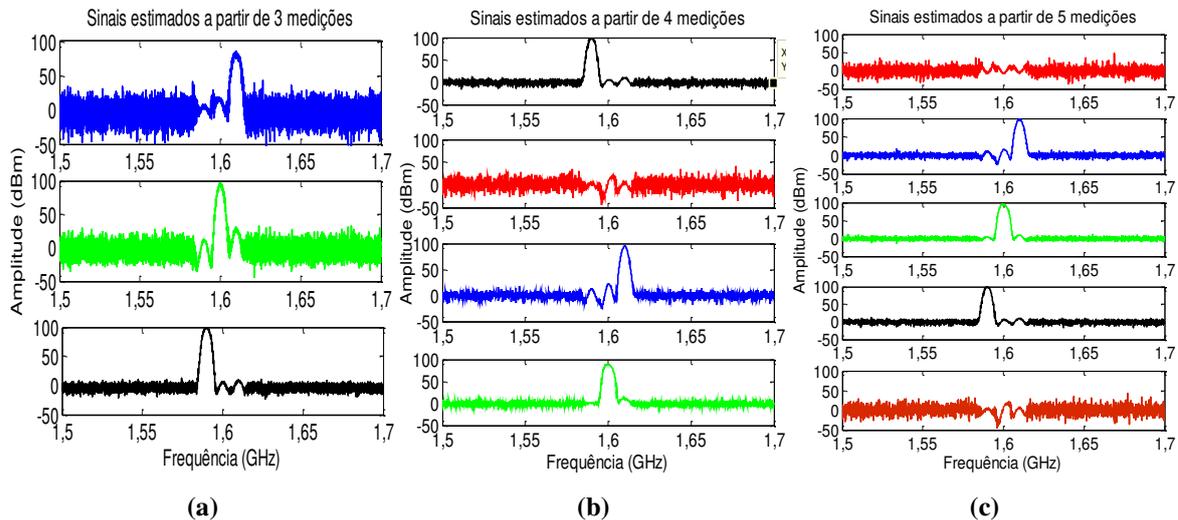


Figura 56 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 55.b, P0 – P2; (b) Sinais estimados a partir dos dados de 4 medições da Figura 55.b, P0 – P3; (c) Sinais estimados a partir dos dados de 5 medições da Figura 55.b, P0 – P4.

Vê-se, na Figura 56.a, que a partir das três medições o ICA já recupera as três fontes desejadas: 1,59, 1,60 e 1,61 GHz, como esperado na teoria. Utilizando a medição em quatro posições diferentes, verifica-se que o ICA distingue claramente as fontes esperadas onde as raias próximas das frequências desejadas possuem amplitudes menores que no caso anterior (três medições). A utilização de cinco medições (Figura 56.c) confirma a existência de apenas três fontes desejadas e que as demais são ruído. Além disso, percebe-se uma melhoria nos valores de amplitude dos sinais desejados e redução da amplitude das raias indesejadas, como aconteceu no caso estudado na Seção 5.7.

Mesmo tendo uma diferença em frequência de apenas 0,63%, amplitudes muito próximas e a complexidade do ambiente de medição o ICA conseguiu identificar e separar as fontes desejadas usando apenas três medições. Porém, usando mais dados de entrada (mais medições) a resposta é melhorada em termos da redução do nível das raias adjacentes (indesejadas) e aumento do nível das frequências desejadas.

Observação: esse mesmo ensaio também foi realizado com fontes com amplitudes bem diferentes (resultado não apresentado aqui). Os sinais estimados pelo ICA são idênticos aos mostrados nesta seção, porém, observou-se que quando as fontes têm amplitudes mais próximas das componentes

desejadas são mais evidentes e as raias laterais apresentam amplitudes menores.

6.1.3.1. Separação de Fontes com Baixa Relação Sinal-Ruído (SNR)

Nos experimentos anteriores as amplitudes dos sinais fontes foram sempre muito maiores do que o nível médio de potência do ruído, normalmente entre 20 e 30 dB de diferença. Neste ensaio essa diferença foi reduzida para valores iguais e inferiores a 10 dB. Portanto, o objetivo aqui é verificar se o ICA consegue separar múltiplas fontes EM com baixa relação sinal-ruído ($SNR \leq 10$ dB).

A relação sinal-ruído pode ser definida, basicamente, como sendo a relação entre o nível de potência do sinal desejado (P_S) e o nível médio de potência do sinal de ruído (P_N). Matematicamente ela pode ser apresentada na forma linear, expressão (6.1), ou logarítmica como na expressão (6.2). Outras expressões mais complexas para o cálculo da SNR podem ser encontradas em [69].

$$SNR = \frac{\text{Potência do sinal (mW)}}{\text{Nível médio de potência do ruído (mW)}}. \quad (6.1)$$

$$SNR_{dB} = P_{S(dBm)} - P_{N(dBm)}. \quad (6.2)$$

A seguir serão apresentados os resultados para o ensaio usando uma diferença de amplitude de aproximadamente 10 dB entre o valor máximo de potência do sinal desejado (P_S) e o valor médio de potência do ruído (P_N) ($SNR \approx 10$ dB). Em seguida a SNR foi reduzida para 5 dB. Os sinais fontes foram mantidos com amplitudes mais próximas possíveis uma da outra. Mantiveram-se a mesma frequência do ensaio visto na Subseção 6.1.3, ou seja, $F_{Rafena} = 1,60$ GHz, $F_{R\&S} = 1,61$ GHz e $F_{Agilent} = 1,59$ GHz e os mesmos procedimentos de medição. Na Figura 57 são mostrados os gráficos dos sinais fontes para os casos em que $SNR \approx 10$ dB e $SNR \approx 5$ dB, respectivamente.

Nota-se na Figura 57.a, que os níveis dos sinais recebidos na posição P_0 , para cada antena excitada individualmente, são respectivamente: $-56,75$ dBm, $-58,68$ dBm e $-56,27$ dBm, ou seja, potências muito próximas. Situação

semelhante para os gráficos da Figura 57.b. A relação entre o nível máximo do sinal fonte e a média entre os maiores valores de ruído (valores destacados nos gráficos da Figura 57) são apresentados na terceira coluna das Tabelas 8 e 9, a qual denominamos de SNR_{\min} . Os valores foram calculados para os três sinais. Para obtê-los converteram-se os valores de potência para a escala linear e em seguida retornou-se à escala logarítmica. Na quarta coluna das Tabelas 8 e 9, estão os valores para SNR entre o valor máximo de potência do sinal fonte e a média da potência do ruído, a qual denominamos de SNR_{med} (calculada usando a expressão (6.2)). O valor médio de potência do ruído foi de $-68,52$ dBm.

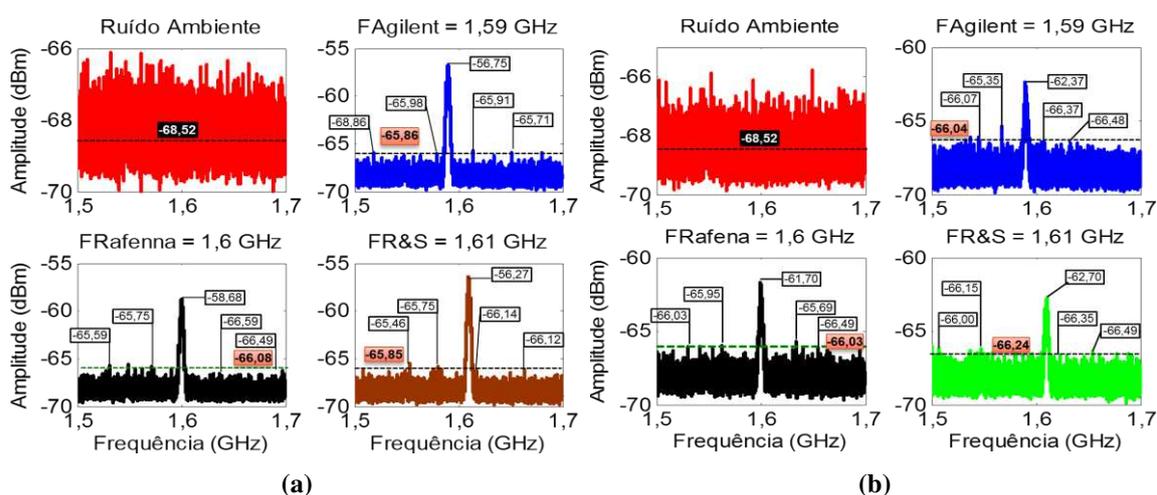


Figura 57 – (a) Sinais fontes, $\Delta F = 0,63\%$ e $SNR \approx 10$ dB; (b) Sinais fontes, $\Delta F = 0,63\%$ e $SNR \approx 5$ dB.

Tabela 8 - Valores da SNR para os sinais transmitidos por cada fonte. Caso de interesse $SNR \approx 10$ dB.

Fontes	Amp _{max} (dBm)	SNR _{min} (dB)	SNR _{med} (dB)
Ger. Agilent (1,59 GHz)	- 56,75	9,11	11,77
Ger. Rafena (1,60 GHz)	- 58,68	7,40	9,84
Ger. R&S (1,61 GHz)	- 56,27	9,59	12,5

Tabela 9 - Valores da SNR para os sinais transmitidos por cada fonte. Caso de interesse $SNR \approx 5$ dB.

Fontes	Amp _{max} (dBm)	SNR _{min} (dB)	SNR _{med} (dB)
Ger. Agilent (1,59 GHz)	- 62,37	3,67	6,15
Ger. Rafena (1,60 GHz)	- 61,70	4,33	6,82
Ger. R&S (1,61 GHz)	- 62,70	3,54	5,82

Como podem ser observados nas Tabelas 8 e 9, os valores de SNR não foram exatamente aqueles desejados: 10 e 5 dB, quando se leva em conta o valor médio de potência do ruído e a potência máxima das fontes. Porém, eles

são próximos dos desejados ainda que os valores de $\text{SNR}_{\text{mín}}$ sejam inferiores aos valores de 10 e 5 dB.

Para os dois casos em estudo foram realizadas medições em posições aleatórias diferentes, mostradas na Fig. 47, Subseção 6.1.1. O resultado destas são expostos na Figura 58.a (caso $\text{SNR} \approx 10$ dB) e na Figura 58.b (caso $\text{SNR} \approx 5$ dB).

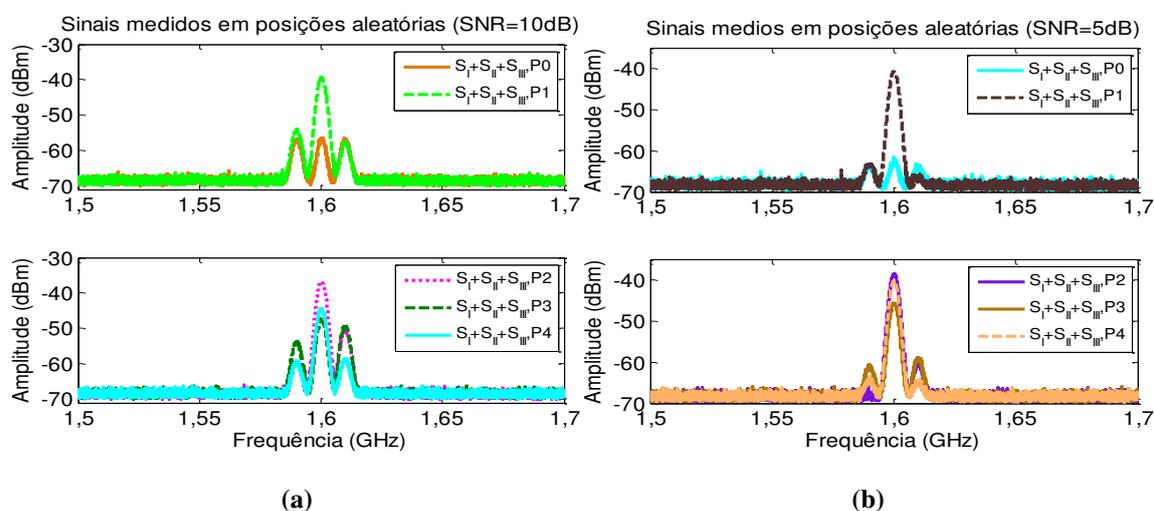


Figura 58 – (a) Sinais misturados, caso $\text{SNR} \approx 10$ dB; (b) Sinais misturados, caso $\text{SNR} \approx 5$ dB.

O comportamento dos sinais medidos nas diversas posições, para os dois casos, é semelhante para a frequência de 1,60 GHz, mas diferentes para as outras duas frequências (1,51 e 1,61 GHz). Esses dados serão aplicados ao algoritmo FastICA para realizar o processo de separação das fontes. Usando apenas as três primeiras medições, obtiveram-se os sinais estimados (componentes independentes) mostrados na Figura 59.a e 59.b, respectivamente para os dados referentes à $\text{SNR} \approx 10$ dB e $\text{SNR} \approx 5$ dB. Nos dois casos, observa-se que o ICA conseguiu distinguir as fontes desejadas usando apenas três medições. Nota-se que aparecem raias indesejadas próximas a componente independente, mas com amplitudes baixas, não dificultando a identificação visual das frequências desejadas. Em geral, a diferença de amplitude entre as raias das frequências desejadas, e as raias indesejadas foi de 77 dB. Importante destacar que mesmo reduzindo consideravelmente a SNR (de 10 para 5 dB) o ICA conseguiu separar e identificar as fontes originais. Aplicações com $\text{SNR} \approx 5$ dB, não foram citadas

em referências como [4, 25], normalmente os valores discutidos lá são superiores a 10 dB.

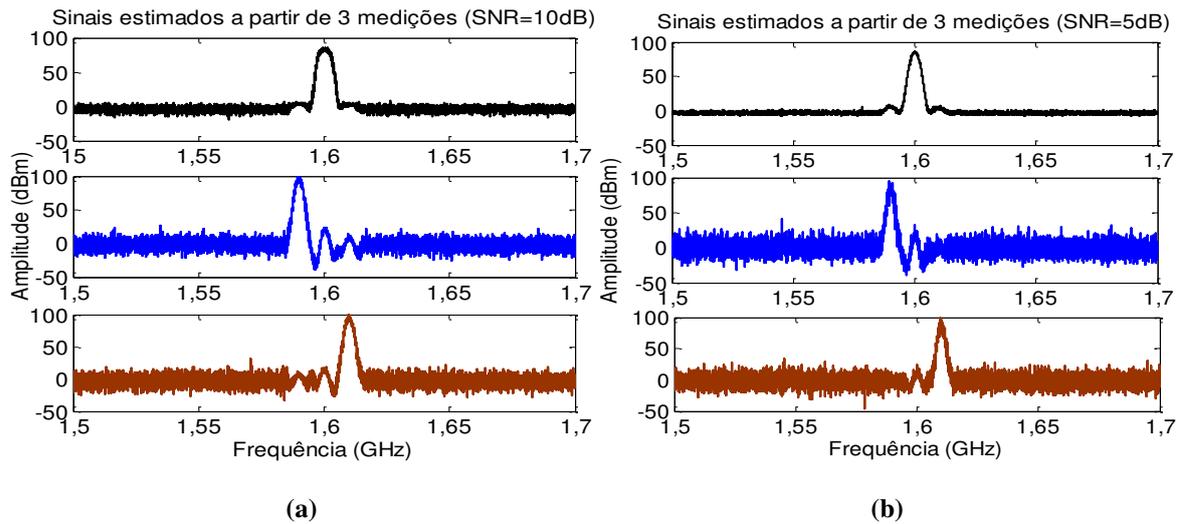


Figura 59 – (a) Sinais estimados a partir de 3 medições obtidas na Figura 58.a (caso $SNR \approx 10$ dB); (b) Sinais estimados a partir de 3 medições obtidas na Figura 58.b (caso $SNR \approx 5$ dB).

Com apenas três medições e nas condições apresentadas o ICA atribui valores significativos apenas para os autovalores relativos aos sinais desejados. Para identificar a fonte de ruído é preciso usar os dados de mais uma medição. Assim, os resultados mostrados na Figura 60 foram obtidos usando as quatro primeiras medições realizadas (P0 – P3).

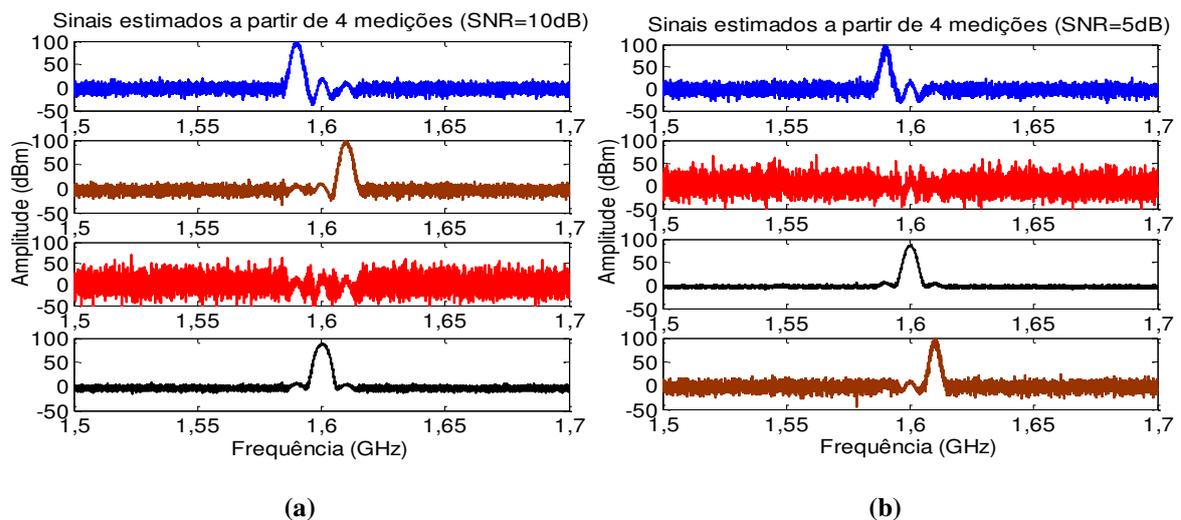


Figura 60 – (a) Sinais estimados a partir de 4 medições obtidas na Figura 59.a (caso $SNR \approx 10$ dB); (b) Sinais estimados a partir de 4 medições obtidas na Figura 59.b (caso $SNR \approx 5$ dB).

Observa-se na Figura 60, que as fontes desejadas e o ruído foram separados pelo ICA a partir de quatro medições, como esperado. Da mesma forma que nos experimentos descritos nas Subseções 6.1.1, 6.1.2 e 6.1.3, a

utilização da quinta medição confirmará que só existem três fontes desejadas e as demais são apenas ruído (resultado não apresentado aqui). Também se observou que à medida que se tem mais dados de entrada (mais medições) há uma melhoria na identificação das frequências desejadas.

O comportamento das componentes independentes é semelhante àqueles observados nos ensaios anteriores em que a relação sinal-ruído era muito maior (entorno de 20 a 30 dB). Isso demonstra que uma vez que o ICA consegue separar as fontes, a amplitude das componentes recuperadas é independente da amplitude dos dados que as originaram.

Portanto, o ICA separa e identifica fontes que tenham relação sinal ruído entorno de 5 dB, usando apenas o número de medições iguais ao número de fontes quando ΔF entre os sinais é maior ou igual a 0,63%. Logo ele pode ser aplicado em situações em que se tenham níveis de ruído relativamente elevados.

6.2 Fontes Produzidas por Rádio Definido por Software (RDS)

Com o intuito de aplicar o ICA a fontes eletromagnéticas (EM) geradas por outro equipamento foram realizados alguns experimentos em que a excitação das antenas transmissoras foi produzida por meio de rádio definido por *software* (RDS). Aqui se usou o RDS apenas para gerar as fontes de sinais, o receptor é o mesmo sistema utilizado nos ensaios com geradores de micro-ondas, ou seja, uma antena conectada ao analisador de espectro que grava os dados e depois se aplica o ICA. Porém, os ensaios abrem a possibilidade de utilização do ICA “embarcado” no receptor compondo um sistema completo de transmissão, recepção e separação de fontes EM via RDS.

O Rádio Definido por *Software* (do inglês – *Software-Defined Radio (SDR)*) foi proposto por Joseph Mitola III [70] como uma implementação de rádio flexível e reconfigurável baseado em *software*. Em comparação com implementações de *hardware* tradicionais, o uso do RDS traz a possibilidade de implementação de várias rádios em um mesmo *hardware*, ou alteração das configurações, ajustando-se os parâmetros via *software*. Além disso, com o

aumento da capacidade de processamento torna-se possível à utilização de processamento de sinal sofisticado nos rádios implementados. O *RDS* é desenvolvido usando programas especializados (*GNU radio*, por exemplo), onde são desenvolvidos os sistemas de rádio e por placas de circuito impresso que permitem ser configuradas conforme a programação recebida. Essas placas são denominadas: “*Universal Software Radio Peripheral (USRP)*”.

O *GNU Radio* [71] é uma “plataforma” de código aberto para o desenvolvimento de RDS. Cada RDS, em *GNU Radio*, é composto por um conjunto de blocos de processamento de sinal interconectados e independentes, obtidos a partir da biblioteca interna da plataforma, ou criados pelo usuário. O RDS desenvolvido utilizando *GNU Radio* pode ser executado em um processador de uso geral, como um computador pessoal, e utilizando uma interface de rádio frequência (RF) é possível transmitir e receber sinais reais.

A USRP [72] é um “*front-end*” de RF composto por uma placa mãe e um conjunto de placas filhas. Na placa mãe, existem conversores analógico-digitais no caminho da recepção (da antena para o computador), conversores digital-analógicos no caminho da transmissão (do computador para a antena) e um Arranjo de Portas Programáveis em Campo, FPGA (*Field-Programmable Gate Array*), para multiplexar os dados, vindo da placa filha de recepção, para o computador e vice-versa.

Os experimentos descritos a seguir abrangem situações em que os sinais são senoidais com frequências bem diferentes e muito próximas. Semelhantes àqueles realizados com geradores de micro-ondas, mas que apresentam outras características em função das fontes geradoras dos sinais.

6.2.1. Fontes com Harmônicas

As fontes EM utilizadas no ensaio com três fontes com harmônicas apresentam ΔF de 200 MHz entre as frequências principais, amplitudes diferentes e foram dispostas colinearmente no espaço livre, a uma distância de $\lambda_0/2$. Portanto, o objetivo desse ensaio é aplicar o ICA a mistura dessas fontes. Para tal, utilizou-se o esquema de medição exibido na Figura 61.

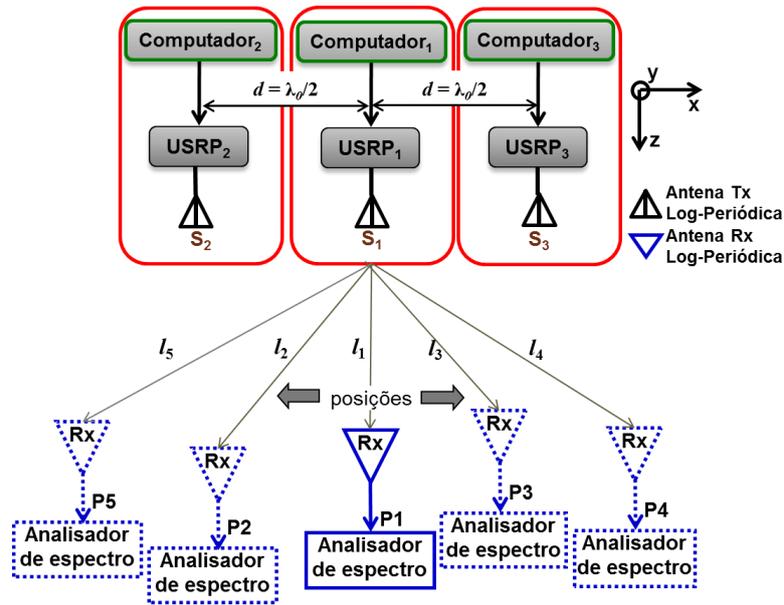


Figura 61 – Esquema de medição para os ensaios usando RDS.

Como representado na Figura 61, cada fonte de sinal é composta por uma USRP conectada ao *GNU Radio* (computador). O RDS permite configurar os parâmetros do sinal transmitido, como a largura de banda, frequência e amplitude. As partes pontilhadas na Figura 61 indicam os pontos de medição P1, P2, P3, P4 e P5, sequencialmente. As posições de Rx (P1 a P5) foram escolhidas aleatoriamente a distâncias l_i entre as antenas transmissora e receptora de: $l_1 = 2,0$ m, $l_2 = 2,6$ m, $l_3 = 2,5$ m, $l_4 = 3,0$ m e $l_5 = 3,2$ m.

No esquema de medição cada transmissor usa uma antena log-periódica planar, modelo WA5JVB conectada a USRP. No receptor, foi usada uma antena log-periódica de alto ganho, banda larga (Rx), modelo A.H Systems, SAS 510-7, conectada ao analisador de espectro, *R&S FSL6*, calibrado para operar na faixa de 1,0 – 1,7 GHz. As antenas transmissora e receptora foram posicionadas na polarização horizontal. As USRPs e os computadores foram conectados via cabo USB (*Universal Serial Bus*); já o USRP e a antena por cabos coaxiais de 1,10 m de comprimento. As frequências usadas foram: $F_{S1} = 1,44$ GHz, $F_{S2} = 1,24$ GHz e $F_{S3} = 1,64$ GHz ($\Delta F = 13,88\%$ em relação à frequência de 1,44 GHz). As frequências escolhidas além de evitarem outras fontes de sinais comerciais evitam múltiplos de 64 MHz, frequência que está relacionada à largura de canal das USRPs [72].

O sistema foi inicialmente calibrado para cada fonte individual. Primeiramente, S_2 e S_3 são desligados, e é feita a medição de S_1 isoladamente; Em seguida, S_1 e S_3 são desligados, e S_2 é medido; finalmente, S_1 e S_2 são desligados e mede-se S_3 . Esses sinais fontes mostrados na Figura 62.a servem de referência para comparação. As três antenas excitadas ao mesmo tempo e medidas em cinco posições diferentes (ver Figura 62.b) resultam nos sinais misturados que serão transferidos para o ICA.

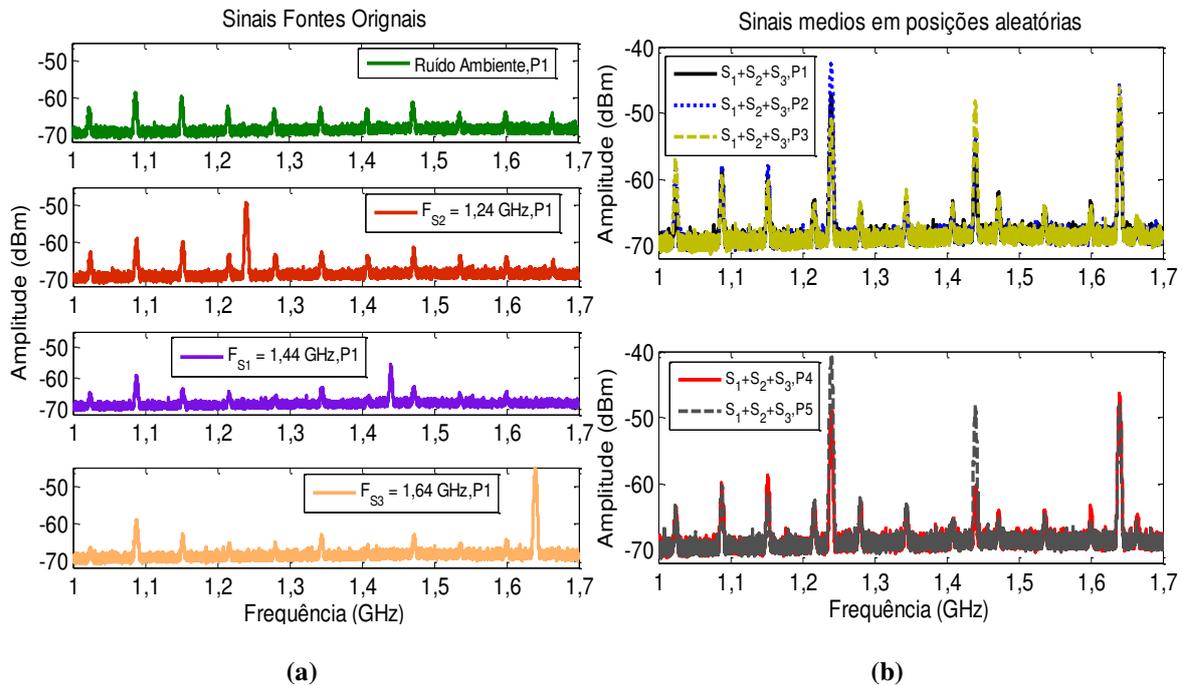


Figura 62 – (a) Sinais fontes produzidos via RDS com $\Delta F = 13,88\%$; (b) Sinais misturados e capturados em cinco posições diferentes.

Na medição do ruído ambiente, parte superior da Figura 62.a, todas as USRPs não estavam conectadas as suas respectivas antenas, porém observa-se que elas geram uma série de harmônicas e estas são irradiadas diretamente pelas placas. No intervalo de medição (1,0 – 1,7 GHz) nota-se 11 harmônicas de 64 MHz. Essas mesmas harmônicas aparecem em cada gráfico das fontes desejadas (demais curvas da Figura 62.a) e também quando todas as antenas estão excitadas, compondo os sinais misturados (Figura 62.b). Portanto, esse ensaio compreende a separação de sinais com frequências desejadas (1,24, 1,44 e 1,64 GHz) e harmônicas de uma fonte não desejada, além do ruído ambiente.

As frequências que são observadas na Figura 62 são: 1,024; 1,088; 1,152; 1,216; 1,280; 1,344; 1,408; 1,472; 1,536; 1,600 e 1,664 GHz, além, de 1,24, 1,44 e 1,64 GHz. A diferença de amplitude entre o valor máximo nos pontos de frequências desejadas e o valor máximo nos pontos de frequências indesejadas, varia entre 10 e 20 dB. O pior caso, 3,86 dB acontece para o sinal desejado de 1,44 GHz e a frequência de 1,088 GHz. As raias com frequências abaixo de 1,24 GHz são normalmente as de maior amplitude em todos os gráficos da Figura 62.

Os dados apresentados na Figura 62.b são submetidos ao método ICA. Na Figura 63.a são apresentadas as componentes independentes (sinais estimados) tomando-se apenas as quatro primeiras medições. Para efeito de verificar se há mais fontes, utilizou-se a quinta medição. O resultado da separação pode ser observado na Figura 63.b.

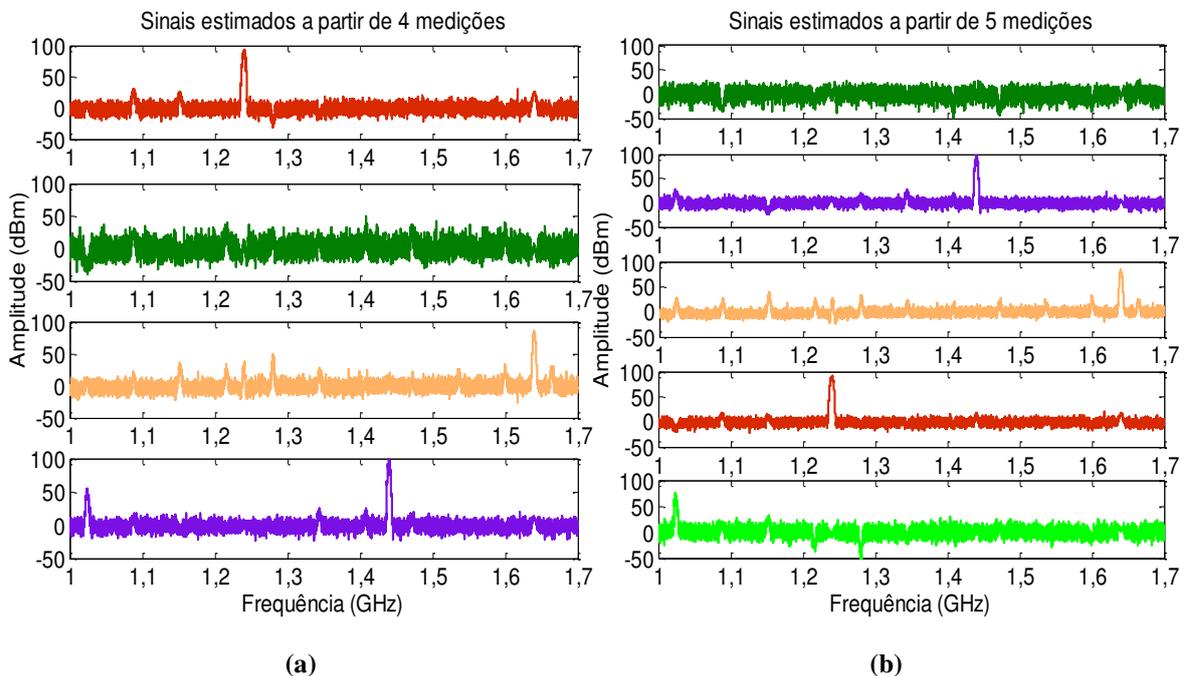


Figura 63 – (a) Sinais estimados a partir de 4 medições da Figura 62.b, $\Delta F = 13,88\%$; (b) Sinais estimados a partir de 5 medições da Figura 62.b, $\Delta F = 13,88\%$.

Quando se observa as componentes exibidas na Figura 63, nota-se que a separação e identificação entre as frequências desejadas, foram realizadas. As harmônicas presentes no ruído original (harmônicas de 64 MHz) aparecem de forma aleatória com amplitudes próximas do nível de ruído, mas visualmente perceptíveis. Nas Figuras 63.a e 63.b vê-se que

algumas dessas harmônicas se repetem, como 1,024; 1,088 e 1,152 GHz, por exemplo. Como todas as USRPs geram harmônicas de 64 MHz era de se esperar que elas se repetissem com maior ou menor influência nos gráficos que contêm as frequências de interesse. Sendo o algoritmo FastICA, um algoritmo iterativo em que a matriz de separação é inicializada de forma aleatória, ora uma harmônica deve aparecer atrelada a uma das frequências de interesse num gráfico ora noutro gráfico, como foi observado acima.

Resultados similares, aos estudados com geradores de micro-ondas, são obtidos quando se usam mais medições do que fontes. É importante notar que no gráfico mais inferior da Figura 63.b o ICA tenta isolar a frequência 1,024 GHz, como se esta fosse uma única fonte senoidal. O que sugere que se fossem realizadas muito mais medições provavelmente obter-se-ia gráficos com uma única frequência. Para isso seriam necessários no mínimo 15 pontos de medição (11 harmônicas + 3 fontes de desejadas + 1 ruído ambiente).

Deve-se salientar que o ICA prioriza os maiores autovalores (frequências desejadas). Com o aumento do número de medições novos autovalores (anteriormente desprezíveis) passam a ser considerados e, portanto, separados.

Assim, pode se dizer que o ICA foi capaz de separar e identificar as três fontes desejadas e mais as harmônicas, presentes nos gráficos dos sinais fontes, mesmo com toda complexidade do ambiente de medição.

6.2.2. Fontes com Frequências Próximas

Com o objetivo de verificar se é possível separar fontes produzidas por RDS, com frequências mais próximas, repetiu-se o experimento 6.2.1 para novas frequências com diferença de apenas 100 MHz.

As características dos sinais fontes originais são: sinais senoidais com amplitudes diferentes e frequências: $F_{S1} = 1,59$ GHz; $F_{S2} = 1,60$ GHz e $F_{S3} = 1,61$ GHz ($\Delta F = 0,63\%$ em relação à frequência 1,60 GHz).

Os procedimentos de medição, os equipamentos e o esquema de montagem são os mesmos descritos na Subseção 6.2.1.

Os sinais fontes, medidos na posição P1, para cada fonte transmitindo individualmente, são mostrados na Figura 64.a. Já as medições realizadas nos pontos P1 – P5, com as três antenas excitadas ao mesmo tempo, são expostos na Figura 64.b.

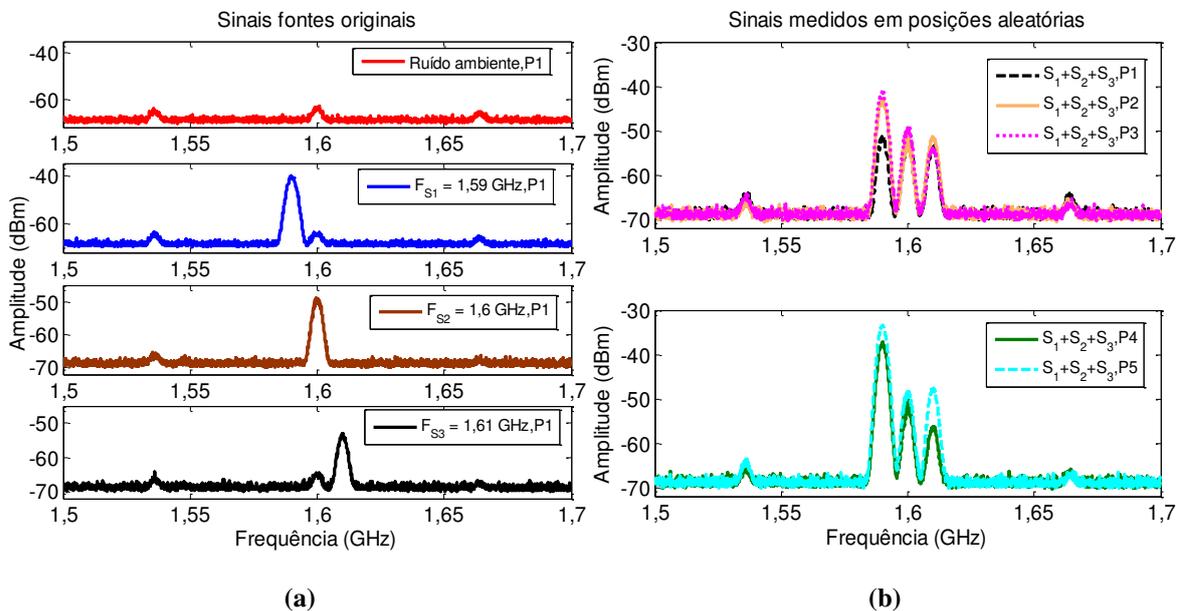


Figura 64 – (a) Sinais fontes produzidos via RDS com $\Delta F = 0,63\%$; (b) Sinais misturados e capturados em cinco posições diferentes.

As frequências harmônicas de 64 MHz observadas na Figura 64 são: 1,536, 1,600 e 1,664 GHz. A 25ª harmônica da USRP (não desejada) coincide com o sinal desejado na frequência de 1,60 GHz. Portanto, existem dois sinais na mesma frequência. Os níveis dos sinais recebidos na posição P0, para cada antena funcionando individualmente, são respectivamente: $-40,28 \text{ dBm}$, $-49,85 \text{ dBm}$ e $-53,02 \text{ dBm}$. Já os picos de amplitude das harmônicas estão em torno de -66 dBm .

Aplicando-se o ICA as três primeiras medições (P1 – P3), obtêm-se as componentes independentes mostradas na Figura 65.a; quando se utiliza quatro (P1 – P4) e cinco (P1 – P5) medições, obtêm-se as componentes independentes mostradas na Figura 65.b e 65.c, respectivamente.

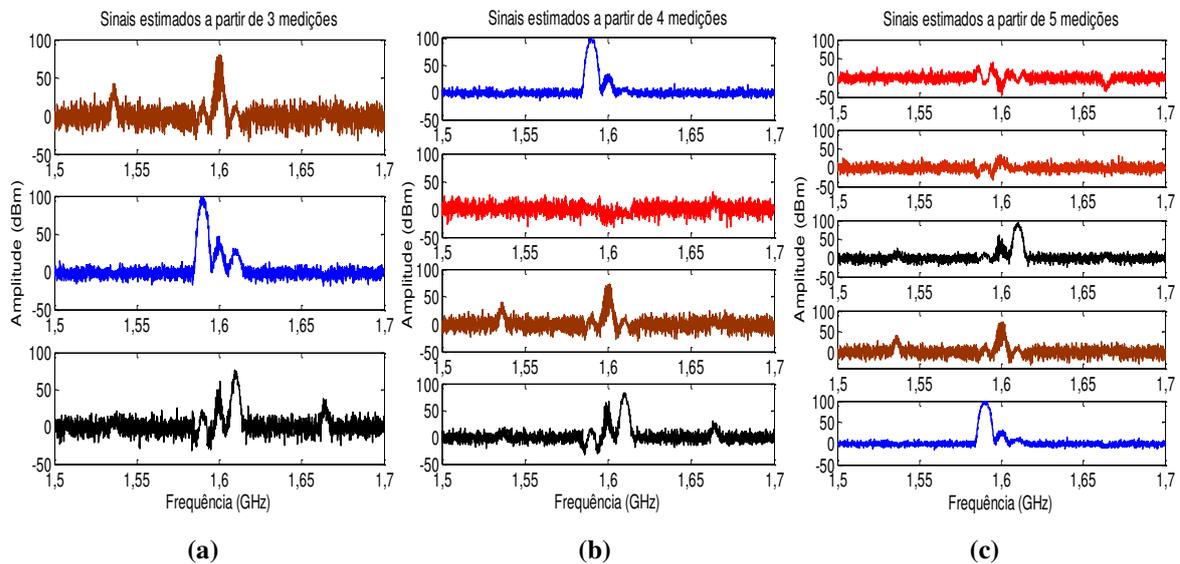


Figura 65 – (a) Sinais estimados a partir dos dados de 3 medições da Figura 64.b, P1 – P3; (b) Sinais estimados a partir dos dados de 4 medições da Figura 64.b, P1 – P4; (c) Sinais estimados a partir dos dados de 5 medições da Figura 64.b, P1 – P5.

Observa-se na Figura 65 que as fontes desejadas foram separadas assim como as harmônicas. Mesmo utilizando-se apenas três medições o ICA conseguiu obter as fontes dos sinais misturados. Com quatro medições obtém-se a fonte de ruído prevista, além das frequências desejadas, o que confirma a existência de apenas três fontes. Com cinco se valida que não há outras fontes dentro da faixa de estudo (1,50 a 1,70 GHz) e aumenta-se a resolução. Note que aparecem raias com pequenas amplitudes ao lado das frequências desejadas, no nível do ruído.

Nota-se que nas Figuras 65.a, 65.b e 65.c aparece uma raia, em 1,60 GHz, com amplitude um pouco acima do nível do ruído ao lado das componentes 1,59 e 1,61 GHz. Ela se refere a 25^a harmônica inerente ao funcionamento das placas USRPs. Ela está presente nos sinais originais (Figura 64.a) ao lado das frequências de 1,59 e 1,61 GHz. Portanto, o ICA separou e identificou, corretamente, as fontes originais, mesmo elas tendo pequena diferença em frequência e com as harmônicas. Durante as medições foi possível determinar uma $SNR = 2$ dB entre a harmônica e o ruído. Portanto, o ICA consegue separar sinais com uma SNR ainda menor do que aqueles valores testados no ensaio da Subseção 6.1.3.1.

6.3 Aplicação do ICA para Sensoriamento Espectral

Nesta Seção será apresentada uma proposta de aplicação do ICA para monitoramento do espectro de rádio frequência (RF), visando aplicação em rádio cognitivo (RC). A novidade nessa proposta está na forma como os resultados obtidos pelo ICA serão analisados e tratados. Até o momento o ICA foi usado para encontrar fontes, ou seja, faixas de frequências onde estão localizadas as fontes de interesse. A característica principal dos métodos usados em sensoriamento espectral é que eles procuram detectar os espaços vazios do espectro monitorado, isto é, espaços onde não existem fontes transmitindo para serem posteriormente usados. A técnica se baseia em utilizar a complementaridade dos resultados obtidos pelo ICA, ou seja, uma vez que o ICA encontre as faixas ocupadas pelas fontes é possível determinar as faixas espectrais onde elas não estão presentes e assim usá-las para transmissão de RC.

O rádio cognitivo é um sistema de rádio que possui a capacidade de adquirir conhecimento, “aprender” sobre o ambiente e tomar as decisões que irão alterar seu funcionamento. Ele tem como referência o padrão IEEE 802.22 usado para comunicações rurais operando com multiplexação OFDM (Multiplexação por Divisão de Frequências Ortogonais). Esses sistemas devem operar sem causar interferências nos sistemas primários (no Brasil os usuários são licenciados pela ANATEL (Agência Nacional de Telecomunicações)) e ocupar os espaços disponíveis no espectro eletromagnético. O nível de transmissão dos sinais deve ser baixo e a banda de frequência deve ser limitada.

O principal desafio para o RC é detectar os espaços disponíveis no espectro para acessá-los e destiná-los para comunicação, evitando qualquer interferência com o usuário licenciado, também chamado de usuário primário nas literaturas que tratam sobre RC. Para evitar a interferência com os sistemas existentes e permitir que novos equipamentos (ou serviços) sejam incorporados têm-se procurado métodos de sensoriamento espectral. A análise do espectro vazio é chamada de detecção espectral e é normalmente realizada

em duas etapas: monitoramento dos canais e utilização das informações obtidas, para decidir se os canais estão ou não vazios.

Os métodos clássicos para sensoriamento espectral são: sensoriamento por detecção de energia, filtros casados e análise de características ciclo-estacionárias do sinal [73, 74, 75]. O método de detecção de energia é computacionalmente simples e tem baixo desempenho, principalmente em um ambiente ruidoso. O método de filtros casados é mais preciso do que o método de detecção de energia, ele maximiza a relação sinal-ruído na presença de ruído aditivo, mas requer informação prévia do usuário primário [76]. Os métodos estocásticos são baseados na análise de algumas características estatísticas do sinal. Esses métodos têm bom desempenho, mesmo em ambientes ruidosos, mas tem alta complexidade computacional e, para melhorar a precisão, exigem o conhecimento prévio das características dos usuários licenciados [77]. Isso pode ser difícil de ser detectado na transmissão de outros usuários secundários (não licenciados). Uma característica comum aos métodos citados acima é que eles são aplicados à detecção espectral de banda estreita.

Um requisito fundamental para as futuras redes de rádio cognitivo é sensoriamento espectral de banda larga, ou seja, os usuários secundários detectarem com segurança oportunidades espectrais em uma ampla faixa de frequência. Os métodos de sensoriamento espectral de banda larga são baseados em tecnologia de amostragem de conversão analógica-digital, as quais exigem altas taxas de amostragem (sensoriamento banda larga, denominado de *Nyquist*); ou conversão analógica-informação, conversor de banda larga modulada com taxas de amostragem mais baixas (sensoriamento banda larga, denominado de *sub-Nyquist*) [76]. Em geral, os métodos de detecção espectral banda larga são computacionalmente complexos, exigem um grande número de etapas de processamento, o que os torna caros e relativamente lentos. O método ICA se apresenta como uma opção para superar esses problemas, tendo em vista que ele tem bom desempenho na presença de baixa relação sinal-ruído (SNR), tem baixa complexidade

computacional [78] e não requer informação prévia sobre os usuários que ocupam o espectro monitorado [79].

Um sistema de RC é composto de várias partes, um exemplo desses é mostrado na Figura 66. No caso prático, o ICA deverá ser inserido no bloco “Monitoração Local de Espectro”, destacado na Figura 66.

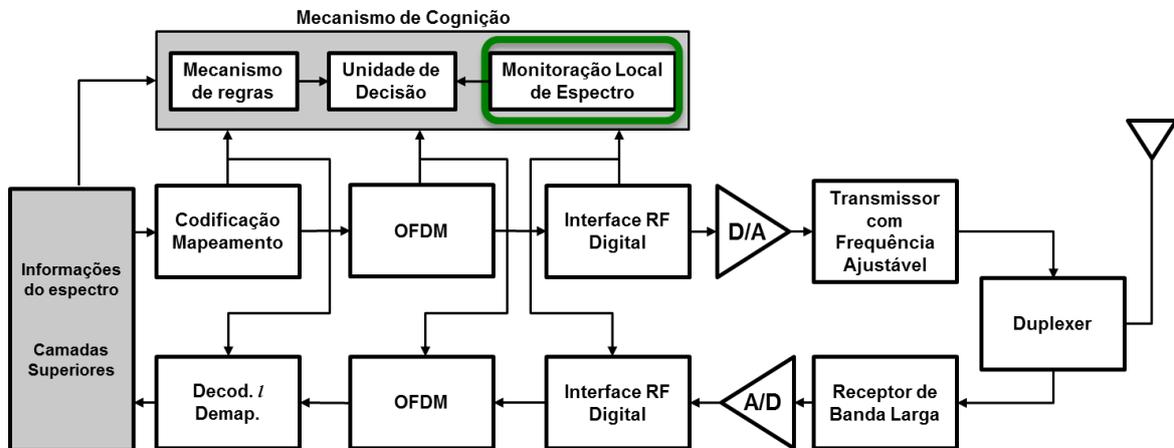


Figura 66 – Diagrama de blocos de um rádio cognitivo baseado em OFDM, modificado de [80].

Como o objetivo aqui não é trabalhar com um sistema de RC propriamente dito, mas sim propor uma forma de sensoriamento para ser aplicado ao RC. Mais informações sobre o funcionamento dos sistemas de RC podem ser obtidas em [81]. A seguir será descrito o experimento para aplicar o ICA no sensoriamento espectral de canais de TV aberta.

6.3.1 Canais de TV (analógica e digital) Abertos

Para validar o uso do ICA para detecção do espectro foi realizada uma montagem experimental para a medição do espectro de canais de TV aberta (canais de tecnologia analógica e digital) e um canal simulado usando um gerador de micro-ondas, como sinais fontes. Os sinais misturados são recebidos por uma antena log-periódica banda larga conectada a um analisador de espectro. Uma vez capturados, os dados são gravados e usados em um aplicativo “*off-line*” do ICA. Cada fonte é considerada como um usuário primário (proprietário licenciado) que transmite um sinal ocupando uma largura de banda específica. Os canais utilizados são sinais das TVs da cidade de Campina Grande, Paraíba, Brasil.

Um primeiro teste foi feito utilizando o RDS com três canais de largura de 6 MHz. O sinal usado foi um sinal “*chirp*”. Este é um sinal que, no domínio do tempo, é uma senoide com frequência variável e no domínio da frequência é um pulso que se desloca dentro da banda desejada (6 MHz por exemplo). O resultado desse teste não são explicitados aqui, mas podem ser encontrados em [79]. Eles serviram de inspiração para a realização deste ensaio e demonstram que o método proposto pode ser também aplicado para sensoriamento espectral provenientes de RDS.

Na Figura 67 é mostrado o esquema de medição com os três usuários primários, e até quatro pontos de medição. As distâncias (d_i , $i = 1, 2, 3$ e 4) entre o transmissor do canal 25 (gerador de micro-ondas) e a antena de recepção (Rx) foram escolhidas aleatoriamente, assegurado a condição de campo distante (RCD). Para os resultados obtidos, as distâncias escolhidas são: $d_1 = 2,30$ m, $d_2 = 2,00$ m, $d_3 = 2,64$ m e $d_4 = 3,20$ m. Enquanto que os sinais dos canais 21 e 23 estão disponíveis no espaço livre. As partes pontilhadas na Figura 67 indicam a sequência de deslocamento do sistema receptor, para a medição nas posições P1, P2, P3 e P4.

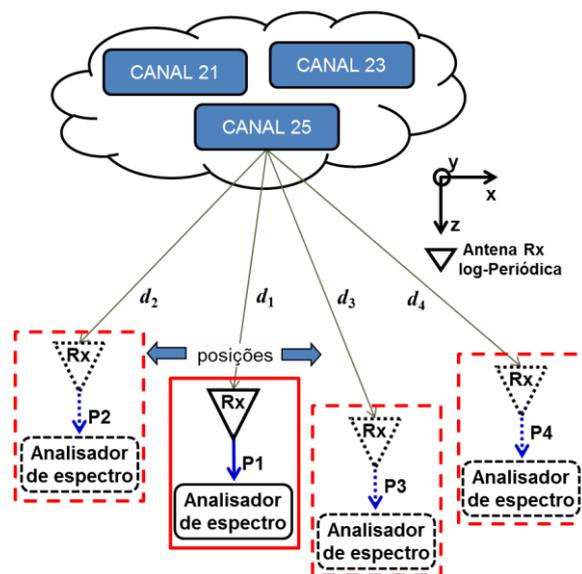


Figura 67 – Esquema de medição para sensoriamento do espectro de TV aberta.

Os canais 21 e 23 transmitem um sinal característico gerado pelas emissoras de TV digital e analógica, respectivamente, com largura de banda de 6 MHz (banda regulamentada pela ANATEL). O canal 25 é um sinal “*chirp*” com a mesma largura de banda do canal de TV. Ele emula o espectro

do terceiro canal de TV (*Observação*: o canal não contém todas as informações de um canal digital real, mas tão somente a largura de faixa e amplitude que um canal digital tem).

Para produzir o canal 25 foi utilizado o gerador de micro-ondas da R&S, SMBV 100A, configurado para gerar um sinal “*chirp*”, com uma largura de banda de 6 MHz. Em seguida, o sinal foi injetado na antena log-periódica (AH Systems, SAS 510-7) por meio de um cabo coaxial. As medições nas posições P1, P2, P3 e P4 foram feitas utilizando o analisador de espectro, R&S, FSL6, conectado a uma antena log-periódica de banda larga (R_X) (R&S, HL040, 0,4 – 3,6 GHz). A largura de faixa de 6 MHz da terceira fonte (canal 25) é obtida pela configuração do gerador de micro-ondas no modo “*Single*”; “*Start frequency*” $F_{st} = 536$ MHz; “*Stop frequency*” $F_{sp} = 542$ MHz; “*Linear Spacing*”; “*Sawtooth Shape*”; e 50 kHz para “*Steplin*”. O analisador de espectro foi configurado para operar de 510 MHz a 544 MHz, com $RBW = 30$ kHz, $VBW = 100$ kHz; “*Trace mode: maximum hold*”, e 10.000 pontos em “*Sweep point*:”.

O sistema foi inicialmente calibrado para medir o espectro de cada usuário individual. Em primeiro lugar, o espectro do canal 21 foi medido como um único canal; em seguida, o canal 23 é medido e, finalmente, o canal 25 é medido. O espectro individual dos três canais, obtidos na posição P1, são mostrados na Figura 68. As medições foram realizadas no espaço livre, cobrindo a faixa de 510 a 544 MHz ($BW = 34$ MHz). Essa largura de banda é 82,35% maior do que a utilizada em [81, 82].

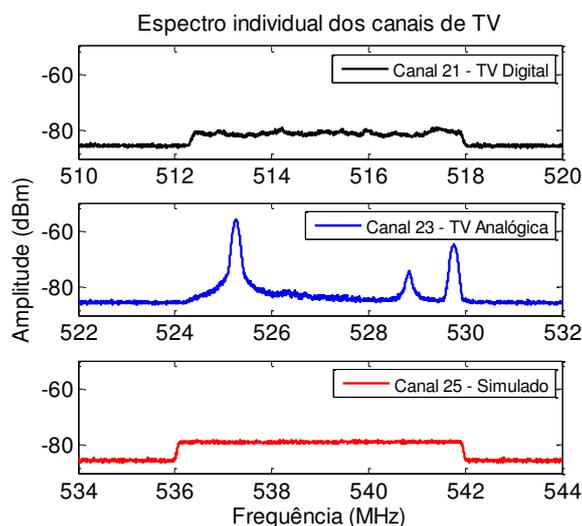


Figura 68 – Espectro original dos usuários primários, medidos na posição P1.

Na Figura 68, pode-se observar que a largura de faixa usada pelos usuários primários é um pouco menor do que a largura de faixa ideal dos canais de televisão (6 MHz). Lembrando que o objetivo dos métodos de sensoriamento espectral é detectar espaços vazios entre os usuários primários. Uma vez que o ICA pode detectar as faixas de transmissão dos canais de TV, será possível determinar os espaços vazios do espectro por complementação.

Os detalhes sobre os sinais de cada usuário primário são explicitados na Tabela 10. A relação sinal-ruído do canal 23 é muito maior do que a dos canais 21 e 25, conforme calculado na Tabela 10.

Tabela 10 - Parâmetros dos usuários primários (Canais de TV aberta)

Usuários primários	Parâmetros		
	Larguras de faixas licenciadas, oficial (MHz)	Potência máxima (dBm)	Relação sinal-ruído SNR (dB) *
Canal 21	512 – 518	- 78,98	06,02
Canal 23	524 – 530	- 55,91	29,09
Canal 25	536 – 542	- 78,17	06,83

* A potência média do ruído foi considerada no cálculo da SNR ($SNR_{dB} = P_{Max} - P_{Med.Noise}$)

O espectro misturado dos sinais recebidos (canal 21 + canal 23 + canal 25) em quatro posições diferentes é mostrado na Figura 69. Esses dados são as únicas informações que serão utilizadas para a identificação das faixas ocupadas pelos usuários e conseqüentemente, determinação dos espaços vazios para transmissão de RC.

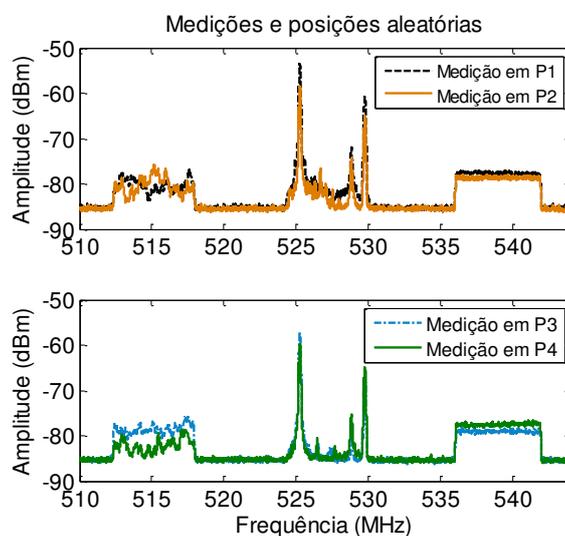


Figura 69 – Composição do espectro recebido nas posições P1 –P4.

Na parte superior da Figura 69 encontra-se o espectro do sinal recebido, exemplo de três usuários licenciados, medidos nas posições P1 e P2 (canal 21 + canal 23 + canal 25) e na parte inferior o espectro medido nas posições P3 e P4. Note que o espectro tem faixas vazias (530 a 536 MHz, por exemplo) entre aquelas atribuídas para os usuários primários. Em um caso prático são esses espaços que devem ser encontrados por qualquer método de detecção espectral apresentados nas seções anteriores [76]. Neste trabalho foi utilizado o método ICA para determinar as faixas que estão ocupadas e, conseqüentemente, vazias em toda a banda monitorada. A vantagem do uso do ICA está, portanto, na capacidade de detecção de uma só vez, sem a necessidade de fracionar espectro em intervalos, por exemplo, de 512 – 518 MHz, depois de 518 – 524 MHz, etc. como é feito nos métodos espectrais tradicionais.

Trabalhos anteriores sobre a aplicação do ICA para decisão de ocupação do espectro têm por base a determinação da curtose dos sinais após separação [84, 85]. Métodos baseados no uso da curtose são susceptíveis a “outliers” [4]. Nestes trabalhos, as conclusões foram obtidas usando dados simulados. Aqui se usou dados medidos e a negentropia. Parâmetro estatístico que não sofre com o problema de “outliers”.

Para ilustrar como o método de detecção de energia é usado na determinação dos espaços vazios no espectro analisado (510 – 544 MHz) foi realizado os cálculos desse método. A energia é calculada em cada intervalo de frequência, resultando nos valores mostrados na Tabela 11. Isso não é necessário quando se usa ICA aos sinais da Figura 69.

Teoricamente os valores de energia, podem ser determinados pela expressão (6.3) descrita em [81].

$$L_{DE} = \frac{1}{N} \sum_{n=0}^{N-1} |y[n]|^2. \quad (6.3)$$

Em que L_{DE} é definido como a energia média do sinal de RF recebido em N amostras, que na verdade é a potência do sinal contida nas N amostras. $y[n]$ representa o sinal no tempo discreto. Para determinar a energia a partir dos valores no domínio da frequência (potências), a expressão (6.3) deve ser

submetida à transformada de Fourier. Na prática os sinais obtidos no analisador de espectro já estão em unidades de potência (P_{medido}), portanto, a (6.3) pode ser reescrita como em (6.4) para obter os valores da Tabela 11.

$$\hat{L}_{DE} = \frac{1}{N} \sum_{n=0}^{N-1} P_{medido} [n](W). \quad (6.4)$$

Tabela 11 - Valores de energia para o espectro mostrado na Figura 69.

Faixas de frequência (MHz)	Canal de referência	Nível do sinal (dBm)	Situação
512 – 518	Canal 21	-80,63	Ocupado
518 – 524		-85,31	Vazio
524 – 530	Canal 23	-71,43	Ocupado
530 – 536		-85,34	Vazio
536 – 540	Canal 25	-78,76	Ocupado

Apesar do nível de sinal ser baixo (Tabela 11), é possível diferenciar o nível de sinal das faixas que estão ocupadas daquelas que não estão. Observa-se que nas faixas de frequência em que a banda está ocupada o nível de sinal é superior a -81 dBm; já onde se têm espaços vazios (apenas ruído) o nível de sinal é inferior a -85 dBm. A diferença de aproximadamente de 4 dB entre as duas faixas (ocupadas e vazias) referem-se ao caso específico tratado nesse exemplo. Valores menores que 4 dB podem inviabilizar a identificação dessas faixas por outras técnicas, em particular o método da energia.

Portanto, como mostrado anteriormente é de se esperar que o método ICA identifique essas mesmas faixas de frequência sem que seja necessário subdividir o espectro em subfaixas.

As medições obtidas na Figura 69 foram usadas como dados de entrada do método ICA. Nenhuma informação adicional é necessária no receptor, como em [75] e [76], por exemplo, em que é assumido que o receptor já conhece a largura de banda dos canais e a frequência da portadora. Inicialmente, foram consideradas apenas três medições do espectro apresentado na Figura 69 (P1 – P3). Teoricamente, são necessárias apenas essas três medições. Os resultados para o espectro estimado usando o algoritmo FastICA estão expostos na Figura 70. Todos os gráficos apresentados abaixo foram submetidos a uma suavização de 0,001% por meio do método da média móvel [56] e, normalizados.

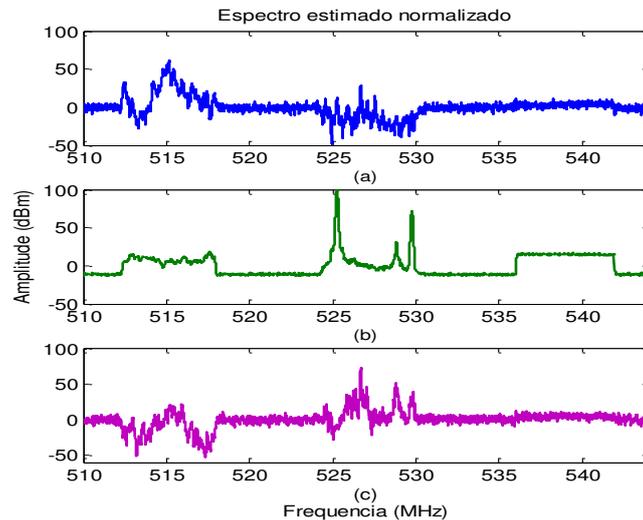


Figura 70 – Espectro estimado usando o método ICA, considerando somente 3 medições daquelas mostradas na Figura 69.

Na Figura 70 pode-se observar claramente as faixas ocupadas pelos usuários primários em três bandas: no gráfico (a) e (c) vê-se a presença da transmissão dos canais 21 (512 – 518 MHz) e 23 (524 – 530 MHz) que também é confirmada no gráfico (b); e em (b) têm-se claramente a informação de ocupação por parte do canal 25 (536 – 542 MHz). Do resultado acima, identificam-se quatro oportunidades espectrais (faixas vazias) disponíveis para transmissão de RC. Essas oportunidades estão destacadas na Figura 71. Note que se tem a informação de ocupação das faixas em separado, quando se vê os gráficos da Figura 70, e que elas são as mesmas quando se mostra os gráficos juntos, Figura 71, não deixando dúvidas de quais faixas estão ocupadas e quais estão vazias na faixa de 34 MHz analisada (510 – 544 MHz).

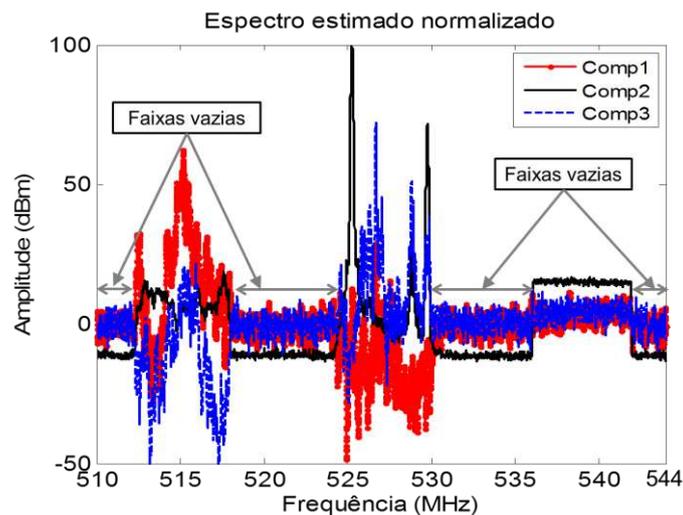


Figura 71 – Espectro estimado pelo ICA, destacando as faixas vazias.

As informações sobre faixas vazias é o objetivo desse ensaio, uma vez que indica onde os usuários secundários podem ser alocados para transmitir (Figura 71). Para determinar as larguras de banda se considerou os pontos onde o sinal cruza o 0 dBm. Observa-se que as larguras de banda são muito próximas das originais (Figura 68). Os detalhes sobre as oportunidades espectrais (faixas vazias) estimadas pelo ICA estão na Tabela 12. Nota-se que as oportunidades espectrais, somam uma banda de 16,3 MHz.

Tabela 12 - Faixas recuperadas pelo método ICA, usando 3 pontos de medição.

Faixas de frequências (MHz)							
Ocupadas		512,2 – 518,0		524,3 – 530,2		536,0 – 542,0	
Vazias	510,0 – 512,2		518,0 – 524,3		530,2 – 536,0		542,0 – 544,0

Comparando-se as faixas dos usuários primários (teoricamente de 6 MHz) com as faixas ocupadas, detectadas pelo ICA, verifica-se erros relativos de 3,33% (canal 21), 1,67% (canal 23) e 0,00% (canal 25). Portanto, o método proposto consegue identificar a largura de faixas ocupadas com pequenos erros comparativamente com o valor das faixas teóricas. É importante lembrar que o método ICA não recupera os mesmos valores de amplitude dos sinais originais, já que a separação é feita sem nenhuma informação prévia dos canais ou do ambiente em que eles estão inseridos. Assim, não têm sentido calcular a energia de cada uma das faixas recuperadas pelo ICA na Figura 71 e compará-los com os valores da Tabela 10. Porém, vale destacar que nos locais onde o ICA encontra as larguras de faixa vazia e ocupada, correspondem às mesmas encontradas pelo método de sensoriamento por detecção de energia. A vantagem do ICA é que se pode observar os espaços vazios de uma única vez. Não é necessário observar intervalo por intervalo, como no método da energia ou outro método de sensoriamento espectral tradicional, para se chegar à conclusão onde estão localizadas as faixas vazias.

Procurando reduzir o erro nas larguras de faixas estimadas, outra medição foi considerada na estimativa, como em [79]. O resultado do espectro estimado, obtido a partir de quatro pontos de medição (P1 – P4) é mostrado em gráficos separados (Figura 72.a) e juntos (Figura 72.b).

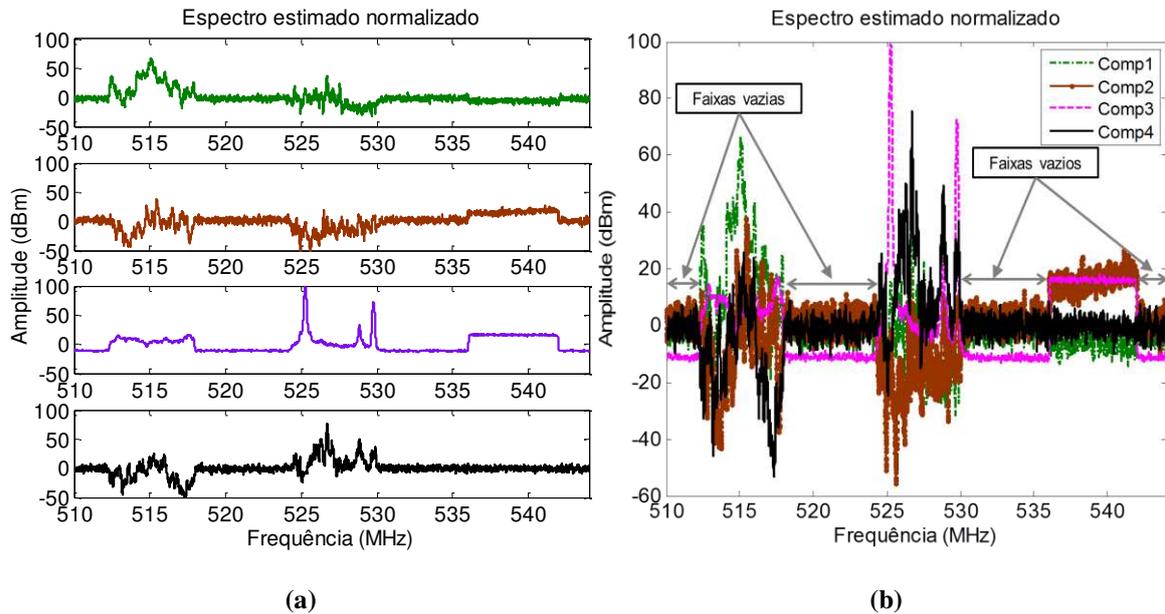


Figura 72 – Espectro estimado pelo ICA, a partir dos dados da Figura 69, nas posições P1 e P4. (a) espectros separados; (b) espectros juntos.

No novo espectro estimado, visto na Figura 72, as larguras de faixa ocupadas pelos usuários primários estão mais próximas do espectro original. Essa visualização só é possível aumentando várias vezes os gráficos da Figura 72. Razão pela qual se obtêm valores com as casas decimais apresentadas nos cálculos a seguir. As larguras de faixa estimadas, ocupadas pelos usuários primários, são: 5,86 MHz, 5,95 MHz e 6,01 MHz. Os erros relativos à banda (teórica) de 6 MHz foram: 2,33%, 0,83% e -0,17%. Uma vez que as faixas foram determinadas, pode-se usar essas informações para identificar os espaços vazios: 512,20 – 510,00 MHz (BW = 2,20 MHz); 524,13 – 518,06 MHz (BW = 6,07 MHz); 535,98 – 530,08 MHz (BW = 5,9 MHz); e 544,0 – 541,99 MHz (BW = 2,01 MHz). Totalizando 15,98 MHz.

Como esperado, com mais dados de entrada o método ICA atingiu maior precisão na identificação das faixas ocupadas pelos usuários primários e as faixas de frequências vazias, objeto de interesse para aplicações de RC. Devido ao fato do ICA ter um espaço de busca maior (mais dados de medição) do que no caso dos métodos de detecção espectral tradicional (normalmente usam apenas uma medição), lhe permite um melhor aproveitamento das características estatísticas do espectro medido. Isso ajuda na confirmação de que há (ou não há) outros usuários primários usando a banda investigada. Um

exemplo vantajoso disso seria uma situação em que existissem usuários piratas transmitido em bandas licenciadas ou entre elas. Usando apenas uma medição correr-se-ia o risco de não detectá-los, pois eles podem usar qualquer faixa de frequência no espectro de RF. Outro exemplo é o caso dos sistemas operando na mesma banda, como as de redes *ad hoc* e o sistema móvel celular, sendo este licenciado, mas também de sistemas que podem compartilhar a mesma banda como os sistemas IEEE 802.11 (sistemas *WiFi*) e o IEEE 802.15 (sistemas *Bluetooth*), que usam simultaneamente a banda ISM (*Industrial, Scientific, and Medical*) [80].

A necessidade de mais dados de entrada para fazer uma estimativa melhor não compromete o custo computacional do algoritmo FastICA. Os resultados obtidos são promissores por mostrarem que o ICA pode ser aplicado para sensoriamento espectral e, portanto, uma opção promissora para aplicação em RC.

Os canais monitorados cobriram as tecnologias de TV analógica e digital, validando a potencialidade do ICA com relação aos métodos tradicionais para sensoriamento espectral.

As características do método proposto permite detectar a existência de outros usuários que não são licenciados (usuários piratas, por exemplo). O ICA também pode varrer uma ampla faixa de frequência, sem comprometer a complexidade e velocidade do algoritmo. Obtêm-se uma resposta mais precisa, quando se tem mais dados de medição (pontos de medição). Além disso, O método proposto demonstra ser uma opção poderosa para sensoriamento espectral de TV de alta definição (HD TV), TV analógica, canais de rádio AM e FM, sinais de microfone sem fio, mesmo se, por acaso, um sistema estiver invadindo a faixa de operação do outro. Uma restrição do ICA em relação aos outros métodos é a necessidade de se ter um conjunto de medições para se determinar e confirmar os espaços vazios no espectro. Porém, isso pode ser superado usando um arranjo de antenas. As medições seriam coletadas individualmente por cada elemento e depois combinadas. Por exemplo, num arranjo de duas antenas poder-se-ia obter até três medições (combinando o espectro da primeira, da segunda e depois das duas antenas juntas). No caso

de um arranjo linear de três antenas ter-se-ia sete possibilidades de combinação de medição.

6.4 Separação de Sinais Modulados em Frequência

Para verificar a aplicação do ICA na separação de fontes de sinais com diferentes modulações serão apresentados a seguir duas situações: na primeira a separação e identificação de três fontes de sinais FM obtidos em simulação computacional, com frequências de portadoras e frequências de modulação diferentes; na segunda a separação e identificação de duas fontes de sinais FM obtidos via experimento em laboratório, com frequência de portadora praticamente igual ($\Delta F_{\text{port}} = 1$ MHz) e frequência de modulação diferente.

6.4.1 Simulação de Três Sinais FM com Frequências Diferentes

Os três sinais FM foram simulados no *Matlab*[®], misturados aleatoriamente e, aos sinais misturados, foi aplicado o FastICA. Os sinais originais apresentam frequência de portadora e frequência de modulação diferente. O objetivo é verificar se o ICA é capaz de identificar e separar essas três fontes eletromagnéticas artificiais. Os sinais das fontes são da forma:

$$\text{Sinal FM } i: s_i = \cos(2\pi f_i t + 2\cos(2\pi f_{\text{mod}i} t)), \quad i = 1, 2 \text{ e } 3. \quad (6.4)$$

Em que, f_1 (100 MHz), f_2 (260 MHz) e f_3 (420 MHz) são as frequências das portadoras; $f_{\text{mod}1}$ (10 MHz), $f_{\text{mod}2}$ (12 MHz) e $f_{\text{mod}3}$ (14 MHz) são as frequências de modulação dos sinais FM, respectivamente.

Os sinais FM foram transformados para o domínio da frequência usando a transformada rápida de Fourier com 10.000 amostras. Os espectros originais dos três sinais FM podem ser vistos na Figura 73. Observe que não há fonte de ruído.

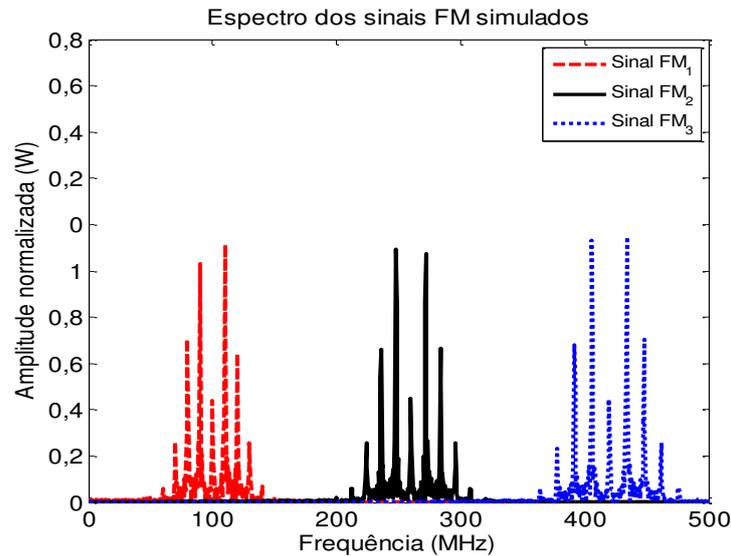


Figura 73 – Espectro dos sinais FM originais, simulados.

No método ICA os sinais da Figura 73, correspondem ao vetor de sinais originais \mathbf{s} . Para obter o vetor de sinais misturados \mathbf{x} ($\mathbf{x} = \mathbf{A}\mathbf{s}$) foi escolhida, aleatoriamente, a matriz de misturas \mathbf{A} , cujos valores foram:

$$\mathbf{A} = \begin{bmatrix} 0,4018 & 0,1233 & 0,4173 \\ 0,0760 & 0,1839 & 0,0497 \\ 0,2399 & 0,2400 & 0,9027 \end{bmatrix}. \quad (6.5)$$

Uma vez obtido os sinais misturados (vetor \mathbf{x}) Figura 74.a, aplicou-se o ICA a esses dados visando à separação e identificação das fontes originais apresentadas na Figura 73. As componentes independentes, ou seja, os sinais estimados podem ser vistos na Figura 74.b.

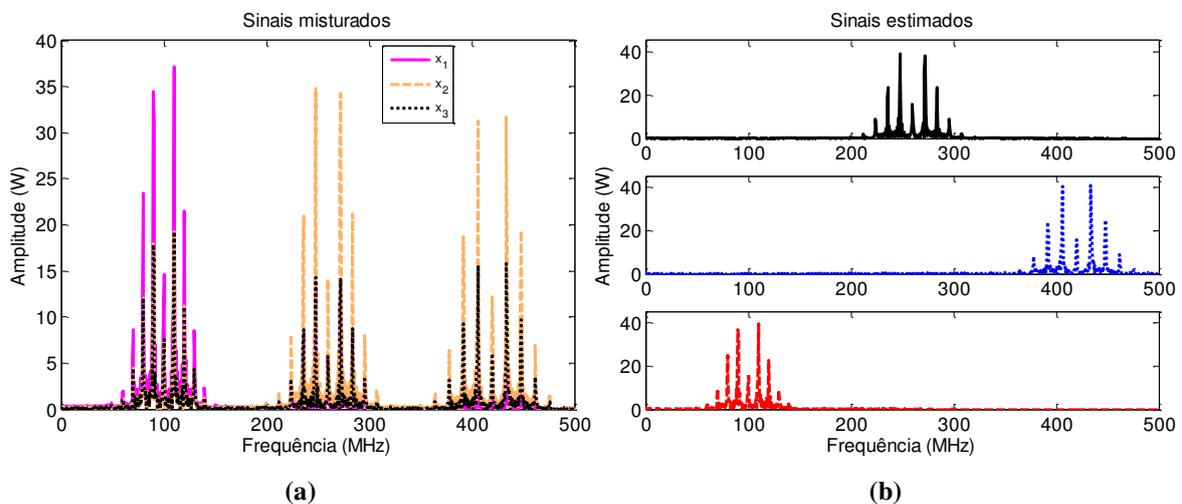


Figura 74 – (a) Sinais misturados aleatoriamente; (b) Sinais FM estimados pelo ICA a partir da mistura dos sinais originais (dados da Figura 74.a).

Nota-se, na Figura 74.b, que os sinais originais foram separados e identificados corretamente, com todas as respectivas raias que compõem o espectro de cada sinal FM original usando apenas três misturas. Portanto, o ICA pode ser aplicado eficazmente para separação e identificação de sinais FM.

6.4.2 Experimentos com Dois Sinais FM com Portadoras Próximas

Visando aplicação do ICA para dados provenientes de geradores de sinais FM, foi realizado um ensaio com dois sinais FM com portadoras praticamente iguais ($\Delta F_{\text{port}} = 1 \text{ MHz}$) e frequência de modulação diferente ($F_{\text{mod1}} = 30 \text{ kHz}$ e $F_{\text{mod2}} = 20 \text{ kHz}$). No ambiente prático o ruído está presente e é considerado, aqui, como uma fonte independente. O objetivo desse ensaio é verificar se o ICA é capaz de identificar e separar os sinais FM em uma situação mais complexa do que aquela descrita na Subseção 6.4.1. Os sinais FM foram gerados a partir de dois geradores de micro-ondas dos fabricantes: *R&S* e *Agilent*. Por sua vez eles foram conectados, via cabo coaxial, a duas antenas log-periódicas planares (WA5JVB). No lado da recepção foi usado o analisador de espectro da *R&S* conectado a uma antena log-periódica (*A.H Systems*, SAS 510-7). Os parâmetros de configuração de cada gerador são descritos na Tabela 13. As frequências das portadoras foram escolhidas para se adequarem as características de ressonância das antenas que dispomos.

Tabela 13 - Configuração dos geradores para produzir sinais FM.

Parâmetros	Gerador <i>Agilent</i>	Gerador <i>R&S</i>
Freq. Portadora (MHz)	999,999	1000
Freq. de modulação (kHz)	30	20
Desvio de Freq. (kHz)	50**	
Amplitude (dBm)	0	0

**parâmetro de configuração interna dos geradores.

Foram utilizados os mesmos procedimentos de medição usados na Subseção 5.6.1, para coleta dos sinais originais e dos sinais misturados. Os resultados dessa combinação são apresentados na Figura 75.a e 75.b, respectivamente. Observa-se que as raias dos dois sinais FM são muito

próximas e que os geradores não produzem o sinal com o mesmo comportamento, principalmente no que se refere ao nível de ruído. O sinal FM produzido pelo gerador *Agilent* produz 9 raias enquanto o sinal FM produzido pelo gerador *R&S* produz 15 raias. Na mistura dos sinais (Figura 75.b), devido a sobreposição de algumas raias, aparecem um total de 17 raias.

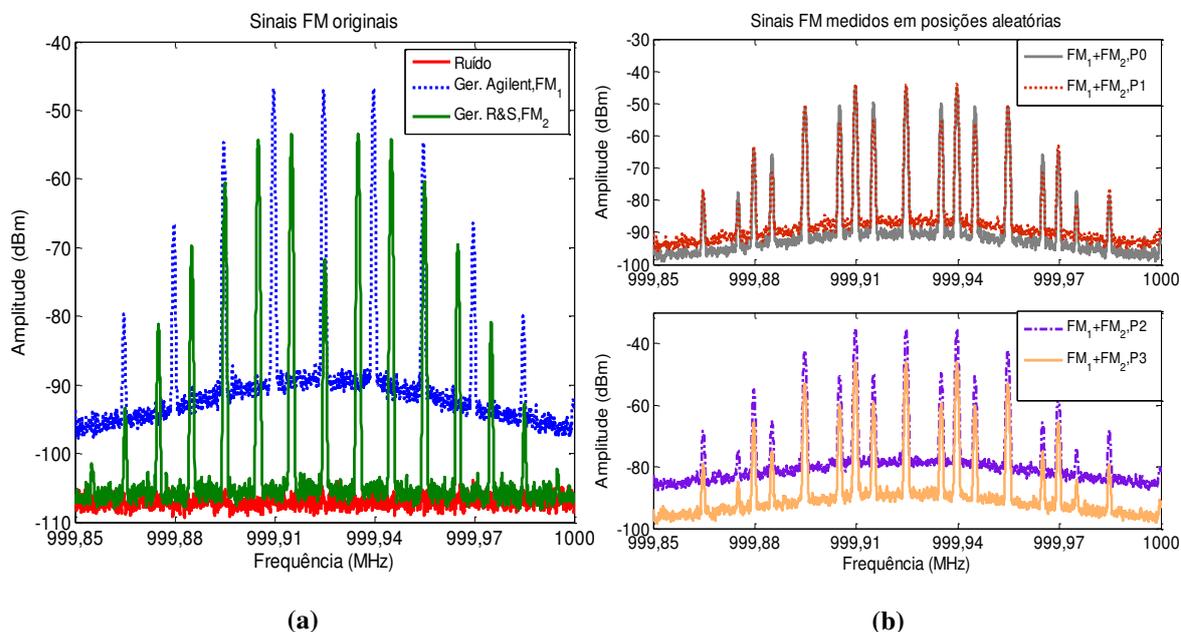


Figura 75 – (a) Sinais FM originais; (b) Sinais FM misturados, medidos em 4 posições aleatórias diferentes.

Aplicando o ICA às medições apresentadas na Figura 75.b se obtêm a separação e identificação dos sinais fontes originais como mostrado na Figura 76. Como foi considerado inicialmente três fontes (dois sinais FM e o ruído) foram usadas às três primeiras medições (P0, P1 e P2). O resultado pode ser visto na Figura 76.a. De forma a complementar a informação de que não existem mais do que duas fontes, utilizou-se a quarta medição, obtendo os gráficos exibidos na Figura 76.b.

Nota-se que o ICA usando apenas três medições conseguiu separar os dois sinais FM e o ruído gerado. Além disso, foi ainda possível identificar, na Figura 76, todas as raias que estão atreladas a cada sinal FM (9 referentes ao gerador da *Agilent* e 15 referentes ao gerador da *R&S*). Portanto, mesmo sendo uma situação mais complexa (sinais FM praticamente com a mesma portadora e frequências de modulação próximas) o ICA conseguiu encontrar os

sinais originais de maneira satisfatória. Esse resultado pode ser expandido para múltiplas fontes FM.

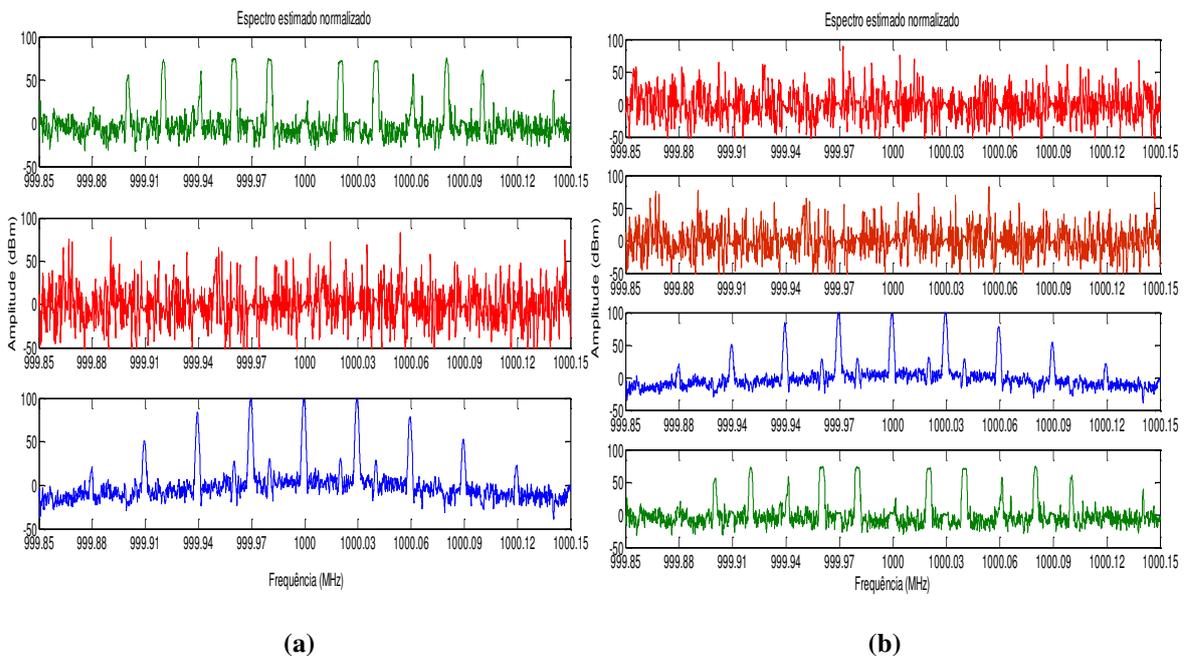


Figura 76 – (a) Sinais FM estimados a partir de 3 medições (P0-P2); (b) Sinais FM estimados a partir de 4 medições (P0-P3).

Observação: para esse ensaio obteve-se os dois sinais FM, já a partir de duas medições, como a teoria do ICA apresenta: para N fontes são necessárias no mínimo N medições (resultado não apresentado aqui). Essa é uma das vantagens do ICA em relação a outros métodos de separação de sinais que necessariamente precisão de mais medições do que o número de fontes.

6.5 Conclusões do Capítulo

Neste Capítulo foram descritos e analisados vários experimentos para aplicação do ICA na separação e identificação de múltiplas fontes eletromagnéticas (EM) irradiantes. Os experimentos englobaram situações em que o ICA não fora investigado, no que tange as aplicações de sinais de micro-ondas e RF, em outras referências. Trabalharam-se situações com fontes de frequências muito distintas ($\Delta F = 14,28\%$), próximas ($\Delta F = 0,63\%$) e muito próximas ($\Delta F = 0,07\%$) e fontes com amplitudes praticamente iguais e diferentes. Foi determinado de forma simulada e experimental, o valor

numérico mínimo de ΔF , entre dois sinais senoidais capaz de ser separado e identificado pelo ICA. Foram apresentados a proposta de usar o ICA para o sensoriamento do espectro de rádio frequência com largura de 34 MHz e a separação de sinais FM, com componentes de frequências que se sobrepuseram.

A qualidade da resposta do ICA não é influenciada pela sequência de combinação dos dados de medição (dados de entrada do ICA).

A menor diferença em frequência entre dois sinais senoidais, determinada via simulação, que a versão do algoritmo FastICA consegue separar e identificar foi $\Delta F = 0,07\%$. Numericamente se podem separar dois sinais com diferença de frequência de 0,000014%, porém, não se consegue distinguir se as componentes obtidas referem-se à fonte s_1 ou a fonte s_2 . Isso acontece para qualquer uma das funções custo testadas, independentemente se é usado o FastICA com ortogonalização simétrica ou deflação. No entanto, foi possível a verificação prática do valor mínimo utilizando-se duas medições a mais do previsto na teoria. O pior caso no erro de separação das frequências desejadas foi menor do que 0,18%.

Para múltiplas fontes com $\Delta F = 0,63\%$ (diferença bem menor do que aquelas encontradas em [10] e [11], com $\text{SNR} \geq 5$ dB, o ICA distingue claramente as fontes esperadas utilizando-se o número mínimo de medições). A utilização de mais medições ajuda na melhoria nos valores de amplitude das raias desejadas e redução da amplitude das raias indesejadas. A amplitude das componentes recuperadas é indiferente à SNR entre as fontes originais.

Com o uso de um sistema de RDS foi possível avaliar o ICA na identificação de harmônicas da fonte original. Foi possível separar fontes com valores de amplitude e de frequências próximas ($\Delta F = 0,63\%$) ou distantes ($\Delta F = 13,88\%$). Nesse exemplo foi possível tratar fontes com pequena diferença em frequência, com $\text{SNR} \geq 2$ dB e uma situação em que coexistia as harmônicas de 64 MHz e os sinais desejados.

Foi apresentada uma proposta de detecção de oportunidades espectrais para transmissão de RC, caso de sinais de TV e de RDS. Um erro máximo de 2,33% foi obtido na determinação das faixas ocupadas e vazias. Ter

mais dados de entrada não compromete o custo computacional do algoritmo FastICA. A vantagem do ICA é o tratamento do espectro com um todo e não por intervalos, como no método de detecção da energia ou outro método de sensoriamento espectral tradicional. Além disso, ele não requer nenhum conhecimento prévio sobre os canais ou do ambiente em que estão inseridos e não exige o envio das propriedades dos sinais transmitidos. Essa combinação de características permite ao método proposto, detectar a existência de outros usuários que não são licenciados (usuários piratas, por exemplo) e sistemas que usam as faixas ISM. Uma restrição no uso do ICA, em relação aos outros métodos tradicionais, é a necessidade de se ter um conjunto de medições para se determinar e confirmar os espaços vazios do espectro. Porém, isso pode ser superado usando um arranjo de antenas, como proposto.

Múltiplos sinais FM também foram separados e identificados pelo ICA para o caso de sinais praticamente sobrepostos.

Como visto ao longo deste capítulo foi possível aplicar o ICA a sinais na faixa de RF e micro-ondas, provenientes de geradores, de RDS e de TV aberta (abrangendo tecnologias digital e analógica). Portanto, a separação de múltiplas fontes EM é possível mesmo se elas estiverem em situações extremas como àquelas apresentadas aqui, utilizando-se, em geral, um número mínimo de medições (número de medições = número de fontes).

Capítulo 7

7. Conclusões

Neste trabalho de tese foram estudadas as aplicações e limitações do método de separação cega de sinais análise em componente independente (ICA) para separar e identificar fontes eletromagnéticas irradiantes, provenientes de geradores de micro-ondas, rádio definido por *software* e sinais de TV. Foi examinada toda a fundamentação teórica do método, sua programação, suas restrições, sua relação com as funções densidade de probabilidade, suas áreas de aplicação, além da análise de qual é a melhor função custo a ser usada primeiro, quando não se tem informação sobre a fdp dos sinais fontes. Também foram explorados vários tipos de experimentos com duas antenas dipolos muito próximas ($d \ll \lambda_0$); fontes de sinais FM praticamente sobrepostos; sensoriamento espectral; múltiplas fontes com antenas log-periódicas planares excitadas por sinais de micro-ondas e RDS com frequências e amplitudes diferentes e muito próximas ($\Delta F = 0,63\%$).

Levando-se em conta as várias simulações e resultados experimentais verificou-se que a função custo $g_3 = y^3$ é a mais adequada para todas as simulações e também para os casos práticos realizados com sinais CW, neste trabalho.

O coeficiente de correlação, parâmetro usado para comparar o quanto os sinais (estimados e originais) têm uma dependência linear forte, mostrou-se adequado ao método. Ele possibilitou uma análise quantitativa entre os sinais estimados e os sinais originais, permitindo avaliar a qualidade da separação, quando as fontes originais estavam disponíveis. Além de indicar se os sinais são linearmente fortes (módulo do coeficiente próximo de 1) é possível inferir se houve inversão de fase entre o sinal estimado e o sinal original, situação detectada quando o coeficiente de correlação é negativo. Além disso, ele pode ser tomado como ferramenta de decisão, conjuntamente

com os resultados da separação das fontes pelo ICA, e ajudar a resolver problemas de identificação da presença de fontes passivas em torno de uma fonte ativa. Para isso, faz-se necessário determinar um limiar para o coeficiente de correlação. Assim será possível decidir se o sinal estimado é referente a uma fonte desejada ou uma parcela desta, devido a reflexões em objeto passivo (refletor, por exemplo).

Baseado nas diversas simulações e experimentos realizados para se ter uma maior segurança de que o sinal estimado, pelo ICA, é o mais próximo possível do original, recomenda-se repetir o processo no mínimo cinco vezes para o caso de três fontes. Não havendo mudança visual nas curvas do sinal estimado tem-se maior garantia de que ele é o sinal original.

Nas simulações de sinais senoidais com pequenas diferenças de fase, o ICA conseguiu separar e identificar as fontes mesmo que estas fossem praticamente às mesmas. Embora essa estimativa seja comprometida pelo deslocamento da fase dos sinais estimados em relação aos sinais originais.

De todos os testes realizados, com duas fontes, apenas o teste prático de se ter o espectro de duas fontes irradiantes idênticas, dispostas uma atrás da outra, não apresentou resultado esperado quando aplicado ao ICA, ou seja, o ICA não conseguiu estimar corretamente as duas fontes originais. Isso motivou a proposta de modificar os procedimentos de coleta de dados para essa situação. A medição da fase e amplitude dos sinais em duas posições via analisador de redes vetorial e, em seguida, a reconstrução matemática do sinal em uma frequência específica (no caso particular 1,8 GHz), para cada posição medida, permitiu que o ICA conseguisse separar os sinais das fontes idênticas S_I e S_{II} . Esse fato demonstra que o procedimento proposto é uma opção para aplicar o ICA nos casos em que a medição somente do espectro de amplitude, não produz informação suficiente para fornecer subsídios à separação e identificação das fontes. O procedimento pode ser estendido para mais fontes.

Demonstrou-se, na prática, que o ICA é capaz de separar e identificar fontes que possuem frequências diferentes, porém muito próximas ($\Delta F = 0,63\%$), pequena distância física ($d = \lambda/10$) e amplitudes próximas ou não, apenas realizando a medição de potência com um analisador de espectro.

Conseguiu-se assim, com o ICA, superar um dos problemas enfrentados pelos métodos baseados em sub-espço (MUSIC e ESPRIT) que é a redução drástica no seu desempenho quando as fontes são senoidais com frequências muito próximas, sem a necessidade de deslocamentos de frequência [11] ou qualquer outro ajuste.

Foi demonstrado, nos casos estudados, que o ICA oferece uma elevada taxa de acertos quando considera o coeficiente de correlação na separação de fontes com distâncias muito pequenas ($d \ll \lambda_0$). Isso evita o uso de arranjos com muitas antenas espaçadas de $\lambda_0/2$, uma vez que sua resposta independe do posicionamento das antenas receptoras (sensores) ou da distância às fontes. Isso poderá ser útil na solução do problema de ambiguidade de fase na estimação da direção de chegada (DoA), quando se tem distâncias diferentes de $\lambda_0/2$.

Inerente ao processo de separação, os sinais estimados sempre apresentarão uma diferença de 90° . Isso inviabiliza a utilização direta da resposta do ICA na determinação da distância entre as fontes.

A aplicação do ICA para o caso da separação e identificação de múltiplas fontes senoidais foi realizada com sucesso. Conseguiu-se separar, na prática, múltiplas fontes com amplitudes iguais e diferentes, com ΔF de 0,63% até 14,28% usando o número mínimo de medições e com $\Delta F = 0,07\%$ usando mais medições. Nos casos testados usaram-se fontes originárias de rádio definido por *software* com harmônicas e múltiplos sinais modulados em FM praticamente sobrepostos.

Determinou-se a diferença mínima numérica que o algoritmo FastICA pode separar e identificar dois sinais senoidais ($\Delta F = 0,07\%$). Fontes com diferenças inferiores a essa só foi possível à separação até o valor de 0,000014%. A partir daí o algoritmo não conseguiu mais separar ou identificar os sinais. Isso aconteceu para qualquer uma das funções custo testadas (g_1 , g_2 ou g_3), independente do uso do FastICA com ortogonalização simétrica ou deflação. A verificação experimental do limite mínimo numérico (0,07%) só foi possível fazendo uso de medições além das previstas na teoria do ICA. Mesmo assim o ICA demonstrou que pode ser usado na detecção de sinais

extremamente próximos (em frequência). O maior erro, nessa situação foi inferior a 0,18% em relação à frequência do sinal original.

Conseguiu-se separar e identificar, visualmente nos gráficos, as múltiplas fontes (de micro-ondas ou por RDS) utilizando-se um número mínimo de medições com $\Delta F = 0,63\%$ e $SNR \geq 2$ dB. O uso de um maior número de medições ajuda na confirmação de que não existem mais fontes do que àquelas já determinadas e aumenta a resolução das mesmas, uma vez que torna os valores de amplitude das raias desejadas mais elevados e reduz a amplitude das raias indesejadas. Assim, na prática deve-se fazer pelo menos $N + 1$ medição (em que N é o número de fontes consideradas). Caso não se tenha ideia do número de fontes, caso real em IEM, deve-se fazer quantas medições forem necessárias para se obter todas as fontes, ou seja, encontrar as fontes desejadas (N) e todas as outras sendo ruído.

Uma vez que o ICA consiga separar as fontes, a amplitude das componentes recuperadas é indiferente à SNR das fontes originais.

Nos testes realizados, a qualidade da resposta do ICA não foi influenciada pela sequência de combinação dos dados de medição (sequência dos dados de entrada do ICA), pela posição relativa entre as fontes (uma atrás da outra ou, lado a lado), pela distância à antena receptora ou pela polarização das antenas transmissora e receptora.

A aplicação do ICA no sensoriamento espectral mostrou-se ser uma opção vantajosa para detecção de oportunidades espectrais disponíveis para transmissão de rádio cognitivo, sejam os sistemas provenientes de sinais de TV ou RDS. Os erros obtidos na determinação das faixas ocupadas e vazias foram relativamente baixos e diminuem com o aumento no número de medições, chegando a no máximo 2,33%, em relação à banda original. Ter mais dados de entrada não compromete o custo computacional do algoritmo FastICA. A vantagem do ICA é que se observam os espaços vazios de uma única vez e não intervalo por intervalo, como no método de detecção da energia ou outro método de sensoriamento espectral tradicional. Além disso, ele não necessita de nenhuma informação prévia sobre os canais ou do ambiente em que estão inseridos e pode ser usado para sensoriamento de banda larga e

estreita [86]. Essa combinação de características permite ao método proposto detectar a existência de usuários não licenciados e sistemas que usam as faixas ISM. Uma restrição do ICA, em relação aos outros métodos tradicionais, é a necessidade de se ter um conjunto de medições para se determinar e confirmar os espaços vazios no espectro. Porém, isso pode ser superado usando um arranjo de antenas, como foi sugerido.

Como visto ao longo deste trabalho foi possível aplicar o ICA a separação e identificação de múltiplos sinais EM com pequenas diferenças de fase, frequência, amplitude e distância ($d \ll \lambda_0$) entre as fontes. Abrangendo fontes EM na faixa de RF e micro-ondas, provenientes de geradores, de RDS e de TV aberta (tecnologias digital e analógica), mesmo se elas estiverem em situações extremas como àquelas apresentadas aqui, utilizando-se, em geral, o número mínimo de medições (número de medições = número de fontes). O que demonstra a potencialidade dessa ferramenta para problemas relacionados à área de micro-ondas e eletromagnetismo aplicados, como: IEM, uso eficiente do espectro eletromagnético, otimização da potência dos sistemas de transmissão sem fio, identificação de sinais piratas, problemas de “*jamming*”, DoA, controle de tráfego veicular, para citar algumas.

7.1. Perspectivas de Continuidade do Trabalho

As sugestões a seguir são baseadas nas discussões e resultados obtidos ao longo do presente trabalho.

- Um estudo aprofundado deve ser desencadeado para se usar o ICA combinado com o coeficiente de correlação para inferir se existem fontes ativas e passivas em um ambiente. Para isso faz-se necessário definir um limiar para o coeficiente de correlação de forma que se possa dizer se as componentes estimadas se referem ao sinal da fonte ativa, se ao da fonte passiva (sinal refletido) ou se apenas ruído;
- Pode-se trabalhar o ICA para aplicação de DoA explorando a característica dele de não ser necessário uso de arranjos de antenas receptoras espaçadas de $\lambda_0/2$, sem causar ambiguidade de fase. Isso também reduziria o tamanho físico dos arranjos;
- Viu-se que não é possível associar diretamente a diferença de fase entre as componentes estimadas e a distância física entre as fontes originais, pois as componentes sempre apresentam uma diferença de 90° . Uma solução proposta para esse problema seria procurar meios para acessar os valores da matriz de separação \mathbf{W} e a partir deles determinar a defasagem. Esse estudo pode ser útil na determinação da distância entre dois veículos, por exemplo, e ajudar os sistemas de controle de velocidade de tráfego.
- Como foi visto a resposta do ICA não depende da distância entre as fontes e os sensores, isso pode ser usado para aplicação, conjuntamente com métodos de localização, em sistemas de controle assistido de veículos. Ele é imune a condições de neblina, fumaça, ambientes noturnos, chuva, etc. Outra vantagem importante é que ele não é afetado pelo eixo de orientação de direção do veículo ou a sua inclinação na estrada. Limitações encontradas em outras técnicas de veículos auto-assistido;
- Todos os ensaios foram feitos de forma “*off line*”, gravando os dados num analisador de espectro e em seguida passando os dados para o

algoritmo FastICA separar e identificar as fontes. Isso pode ser implementado diretamente em RDS para se ter uma ferramenta de avaliação “*on line*” de fontes eletromagnéticas.

Referências Bibliográficas

- [1] W. Z. Song, R. Huang, M. Xu, A. Ma, B. Shirazi, and R. LaHusen, “Air-dropped sensor network for real-time high-fidelity volcano monitoring,” *IEEE Trans. Parallel Distrib. Syst.*, vol. 21, No. 11, Nov. 2010, pp.1658–1674.
- [2] Statutory Instruments, 2012 N° 1519, Electromagnetic Compatibility. The Wireless Telegraphy (Control of Interference from Apparatus) (The London Olympic Games and Paralympics Games) Regulations 2012. Available: <http://www.legislation.gov.uk/uksi/2012/1519/made>
- [3] T. Ko, “Fingerprint enhancement by spectral analysis techniques,” in *Proc. of the 31st Applied Imagery Pattern Recognition Workshop (AIPR.02)*, 2002, Washington, DC, EUA, pp. 133 – 139.
- [4] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*. New York: John Wiley & Sons, 2001.
- [5] T. Ristaniemi and J. Joutsensalo, “On the performance of blind source separation in CDMA downlink,” in *Proc. Int. Workshop on Independent Component Analysis and Signal Separation (ICA’99)*, Aussois, France, 1999, pp. 437–441.
- [6] S. Zhenfei, S. Donglin, D. Fei, F. Duval, and A. Louis, “A novel electromagnetic radiated emission source identification methodology,” in *Asia-Pacific International Symposium on Electromagnetic Compatibility (APEMC)*, April 12 - 16, 2010, Beijing, China, 2010, pp. 657 – 660.
- [7] P. Tichavský, Z. Koldovský, and E. Oja, “Performance analysis of the FastICA algorithm and Cramér-Rao bounds for linear independent component analysis,” *IEEE Transactions on Signal Proc.*, vol. 54, No. 4, pp. 1189 – 1203, Apr. 2006.
- [8] M. Masugi, N. Hirasawa, R. Kobayashi, K. Tajima, and H. Yamane, “Proposal of a novel EMI diagnostic system using independent component

analysis,” in *Proceedings, 20th Int. Zurich Symposium on EMC*, Zurich, 2009, pp. 417-420.

[9] P. I. L. Ferreira, G. Fontgalland e G. F. Aragão, “Identificação de fontes eletromagnéticas muito próximas pela análise da componente independente,” *15^o SBMO – Simpósio Brasileiro de Micro-ondas e 10^o CBmag – Congresso Brasileiro de Eletromagnetismo, (MOMAG 2012)*, 05 – 08 de agosto, 2012, João Pessoa, Brasil, pp. 1 – 5.

[10] T. Iwata, Y. Goto, and H. Susaki, “Application of the multiple signal classification (MUSIC) method for one-pulse burst-echo Doppler sonar data,” *IOPscience – Journals, Measurement Science and Technology*, vol. 12, November 2001, pp. 2178 – 2184.

[11] B. Halder and T. Kailath, “Efficient estimation of closely spaced sinusoidal frequencies using subspace-based methods,” *IEEE Signal Processing Letters*, vol. 4, No 2, February 1997, pp. 49 – 51.

[12] Y. Cheng, N. Yang, X. Yang, and Y. Wu, “Application of independent component analysis in metal corrosion acoustic emission signal processing,” in *2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (IEEE - ICQR2MSE)*, Chengdu, China, February 2012, pp. 648 – 650.

[13] A. Lombard, Y. Zheng, and W. Kellermann, “Synthesis of ICA-based methods for localization of multiple broadband sound sources,” in *IEEE International Conference Acoustics, Speech and Signal Processing (ICASSP)*, Prague, Czech Republic, 2011, pp. 157 – 160.

[14] T. Wu, L. Sun, Q. Cheng, and P. K. Varshney, “Fusion of multiple microphone arrays for blind source separation and localization,” *IEEE 7th Sensor Array and Multichannel Signal Processing Workshop (SAM)*, Hoboken, NJ, USA, 2012, pp. 173 – 176.

- [15] T. Noohi, N. Epain, and C. T. Jin, "Direction of arrival estimation for spherical microphone arrays by combination of independent component analysis and sparse recovery," The 38th International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Vancouver, Canada, on May 26 - 31, 2013, pp. 346 – 349.
- [16] A. K. Khan, T. Onoue, K. Hashiodani, Y. Fukumizu, and H. Yamauchi, "Signal and noise separation in medical diagnostic system based on independent component analysis," *IEEE Asia Pacific Conf. on Circuits and Systems (APCCAS)*, Kuala Lumpur, Malaysia, 2010, pp. 812 – 815.
- [17] R. Zhou, H. Zhang, and H. Xin, "Improved two-antenna direction finding inspired by human ears," *IEEE Trans. Antennas Propagation*, vol. 59, No. 7, pp. 2691–2697, Jul. 2011.
- [18] G. Capizzi, S. Coco, and A. Laudani, "A new tool for the identification and localization of electromagnetic sources by using independent component analysis," *IEEE Transactions on Magnetics*, vol. 43, No 4, pp. 1625 – 1628, Apr. 2007.
- [19] N. Behdad, M. A. Al-Joumayly, and M. Li, "Biologically inspired electrically small antenna arrays with enhanced directional sensitivity," *IEEE Antennas and Wireless Propagation Letters*, vol. 10, 2011, pp. 361 – 364.
- [20] A. Lay-Ekuakille, P. Vergallo, D. Saracino, and A. Trotta, "Optimizing and post processing of a smart beamformer for obstacle retrieval," *IEEE Sensors Journal*, vol. 12, No 5, May 2012, pp. 1294 – 1299.
- [21] M. Carlin and P. Rocca, "A Bayesian compressive sensing strategy for direction-of-arrival estimation," In *6th European Conference Antennas and Propagation (EUCAP)*, 2012, Prague, 26-30 March 2012, pp. 1508 – 1509.
- [22] A. Karpikov, H. Tagare, T. Mulnix, J. Dominique Gallezot, A. Sinusas, C. Liu, and R. E. Carson, "Myocardial blood flow from dynamic pet using independent component analysis," *IEEE Nuclear Science Symposium and*

Medical Imaging Conference Record (NSSIMIC), Anaheim, CA, USA, 2012, pp. 2222 – 2226.

[23] E. H. Meftah, A. Anou, and M. Bensebti, “Noisy ICA-based detection method for compound system MIMO-OFDM in CDMA context,” *5th International Symposium on I/V Communications and Mobile Network (ISVC)*, Rabat, Marocco, 2010, pp. 1 – 4.

[24] W. Hu, S. L. Tantom, and L. M. Collins, “EMI-based classification of multiple closely spaced subsurface objects via independent component analysis,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42. No 11, November 2004, pp. 2544 – 2554.

[25] P. Comon and C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*. Burlington: Elsevier, 2010.

[26] H. Sawada, R. Mukai, S. Araki, and S. Makino, “Multiple source localization using independent component analysis,” *IEEE Antennas and Propagation Society International Symposium*, vol. 4B, July 2005, pp. 81 – 84.

[27] Z. Wang and C.S. Chang, “Online fault detection of induction motors using frequency domain independent components analysis,” in *20th IEEE International Symposium on Industrial Electronics (ISIE’2011)*, Gdansk, Poland, June 2011, pp. 812 – 815.

[28] K. Lee, T. Ikeda, T. Miyashita, H. Ishiguro, and N. Hagita, “Separation of tactile information from multiple sources based on spatial ICA and time series clustering,” *Symposium IEEE/SICE System Integration International (SII)*, Kyoto, Japan, 2011, pp. 791 – 796.

[29] P. Comon, “Separation of stochastic processes,” *In Proc. Workshop on Higher-Order Spectral Analysis IEEE-ONR-NSF*, Vail, Colorado, June 28-30, 1989. pp. 174 – 179.

- [30] E. Oja, J. Karhunen, L. Wang, and R. Vigarío, "Principal and independent components in neural networks – recent developments," *M. Marinaro and R. Tagliaferri (Eds.), Neural Nets WIRN Vietri'95, World Scientific, Singapore, 1995*, pp. 16 – 35. (Invited paper in the 7th Italian Workshop on Neural Nets, Vietri sul Mare, Salerno, Italy, May 18-20, 1995).
- [31] L. T. Duarte. "Um estudo sobre separação cega de fontes e contribuições ao caso de misturas não-lineares". Dissertação (Mestrado em Engenharia Elétrica e Computação), Universidade Estadual de Campinas – UNICAMP, Campinas, 2006.
- [32] Bell A., Sejnowski, T. J., "An information maximization approach to blind source separation and deconvolution". *Neural Computing*, Vol. 7, N° 6, 1995, pp. 1129 – 1159
- [33] L. R. da Silva, "Aplicação da decomposição em valores singulares e análise de componentes independentes em dados de fMRI". Dissertação (Mestrado em Matemática e Estatística), Universidade Federal do Pará – UFPA, 2011.
- [34] T. M. Cover and J. A. Thomas, *Elements of Information Theory*. 2^a Edition. New Jersey, Canadá: John Wiley & Sons, 2006.
- [35] A. Hyvärinen, and E. Oja, "A fast fixed-point algorithm for independent component analysis," *Neural Computation*, 9(7): 1483 – 1492, 1997.
- [36] J. F. Cardoso, "Blind separation: statistical principles," *Proceedings of IEEE*, 86 (10), 1998, pp. 2009-2025.
- [37] A. Hyvärinen e E. Oja, "Independent component analysis: algorithms and applications," *Neural Networks*, 13(4-5), 2000, pp. 411 – 430.
- [38] S. Choi, A. Cichocki, H.-M. Park, and S.-Y. Lee, "Blind source separation and independent component analysis: A Review," *Neural Information Processing - Letters and Reviews*, vol.6. No 1, January 2005, pp. 1 – 57.

- [39] L. Zhang, J. Wang, and N. Ma, “Blind separation and modulation identification of jamming signals in communications,” *International Conference Electronics, Communications and Control (ICECC)*, Ningbo, China, 9-11 Sept. 2011, pp. 170 – 173.
- [40] X. Su, H. Sang, G. Yang, X. Shen, “A novel ICA-based method for image enhancement of polarimetric SAR,” *IEEE 4th International Symposium Microwave, Antenna, Propagation, and EMC Technologies for Wireless Communications (MAPE)*, Beijing, China, 1-3 Nov. 2011, pp. 509 – 512.
- [41] H. Li and X. Zhang, “Blind separation of noisy mixed speech based on independent component analysis and neural network,” in *2012 International Conference Computing, Measurement, Control and Sensor Network (CMCSN)*, Taiyuan, China, 7-9 July 2012, pp.105 – 108.
- [42] X. Wang, Z. Huang, Y. Zhou, and X. Ren, “Novel signal extraction algorithm for communication signals by combining independent component analysis and spatial constraints,” *International Conference on Systems and Informatics (ICSAI 2012)*, Yantai, China, 19-20 May 2012, pp. 1715 – 1719.
- [43] L. Leite. “Análise de componentes independentes à identificação de regiões lesionadas em mamogramas”. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Rio de Janeiro, Rio de Janeiro, abril de 2005.
- [44] A. Karpikov, H. Tagare, J.-D. Gallezot, A. Sinusas, C. Liu, and R. E. Carson, “Myocardial blood flow from dynamic PET using independent component analysis,” *IEEE Nuclear Science Symposium and Medical Imaging Conference Record (NSSIMIC)*, Anaheim, CA, EUA, Oct. 27 2012-Nov. 3 2012, pp. 2222 – 2226.
- [45] E. H. Meftah, A. Anou, and M. Bensebti, “Noisy ICA-based detection method for compound system MIMO-OFDM in CDMA context,” in *5th*

International Symposium on I/V Communications and Mobile Network (ISVC 2010), Rabat, Marocco, 2010, pp. 1 – 4.

[46] S. P. Gomes, P. da S. S. Carvalho, E. Aguiar, A. B. Silva, F. M. Braga, and A. K. Barros, “Localization of generalized discharge sources in patients with juvenile myoclonic epilepsy using independent components analysis,” *In Proceedings of 8th International Conference, ICA 2009*, Paraty, Brazil, March 15-18, 2009, pp. 411.

[47] W. Guo and Q. Zong, “A blind separation method of instantaneous speech signal via independent components analysis,” *in 2nd International Conference Consumer Electronics, Communications and Networks (CECNet)*, Three Gorges, YiChang, Hubei, China, 21-23 April 2012. pp. 3001 – 3004.

[48] K. Lingfu, Gao F. L. Yingwei, L Xingbin, and H. JinHai, “ICA and its application in the phase information extraction of oil-gas-water three phase flow,” *2010 First International Conference on Pervasive Computing, Signal Processing and Applications (PCSPA)*, 17-19 Sept. 2012, pp. 549 – 552.

[49] E. Fishler, M. Grosmann, and H. Messer, “Detection of signals by information theoretic criteria: general asymptotic performance analysis,” *IEEE Transactions on Signal Processing*, vol. 50. No 5, May 2002, pp. 1027 – 1036.

[50] W. Xiong, Yi-Ou Li, H. Li, T. Adalı, and V. D. Calhoun, “On ICA of complex-valued fMRI: advantages and order selection,” *IEEE International Conference Acoustics, Speech and Signal Processing (ICASSP)*, Las Vegas, NV, 2008, pp.529 – 532.

[51] M. Hui, J. Li, X. Wen, L. Yao, and Z. Long, “An empirical comparison of information-theoretic criteria in estimating the number of independent components of fMRI data,” *in PLoS ONE*, vol. 6. No 12, Dec. 2011, pp. 1 – 10.

[52] T. M. Cover and J. A. Thomas, *Elements of Information Theory*. 2^a Edition. New Jersey, Canadá: John Wiley & Sons, 2006.

- [53] P. Comon, “Independent component analysis, a new concept?,” *Signal Processing*, 36 (6), 1994, pp. 287 – 314.
- [54] R. Suyama. “Proposta de métodos de separação cega de fontes para misturas convolutivas e não-lineares”. Tese (Doutorado em Engenharia Elétrica e Computação), Universidade Estadual de Campinas – UNICAMP, Campinas, 2007.
- [55] E. de S. Rosa. “Separação cega de sinais em sistemas ópticos com multiplexação de polarização”. Dissertação (Mestrado em Engenharia Elétrica e Computação), Universidade Estadual de Campinas – UNICAMP, Campinas, 2010.
- [56] J. A. Gubner, “Probability and random processes for electrical and computer engineers”. Ed. Cambridge, Cambridge, 2006.
- [57] A. Hyvärinen, “Fast and robust fixed-point algorithm for independent component analysis,” *IEEE Transactions on Neural Networks*, vol. 10. No 3, May 1999, pp. 626 – 634.
- [58] P. I. L. Ferreira and G. Fontgalland, “Blind separation of multiple electromagnetic radiation sources,” *Antenna Measurement Techniques Association, (AMTA 2013)*, October 6-11, Columbus, Ohio, EUA, pp. 494 – 497.
- [59] A. Hyvärinen, "One-unit contrast functions for independent component analysis: A statistical analysis," in *Proceeding of Neural Networks for Signal Processing VII (Proc. IEEE Workshop on Neural Networks for Signal Processing)*, Amelia Island, Florida, 1998, pp. 388-397.
- [60] S. Amari, A. Cichocki, and H. H. Yang, “A new learning algorithm for blind signal separation,” *Advances in Neural Information Processing Systems*. The MIT press, 1996, pp. 757 – 763.

- [61] E. Oja, “Convergence of the symmetrical FastICA algorithm,” in *Proceedings of the 9th International Conference on Neural Information Processing (ICONIP’02)*, vol. 3, 2002, pp. 1368 – 1372.
- [62] S. A. Lira. “Análise de correlação: abordagem teórica e de construção dos coeficientes com aplicações”. Dissertação (Mestrado em Métodos Numéricos em Engenharia dos Setores de Ciências Exatas e de Tecnologia), Universidade Federal do Paraná – UFPR, Curitiba, 2004.
- [63] F. A. de Lima Moreto. “Análise de componente independente à separação de sinais de áudio”. Dissertação (Mestrado em Engenharia Elétrica), Escola Politécnica da Universidade de São Paulo, São Paulo, 2008.
- [64] P. I. L. Ferreira, G. Fontgalland, and B. B. Albert, “Identification of sources with small phase difference by the method of independent component analysis,” *Digests of the 15th IEEE Conference on Electromagnetic Field Computations (CEFC)*, Oita, Japan, Nov. 11 –14, 2012.
- [65] P. I. L. Ferreira, G. Fontgalland, S. E. Barbin, and G. F. Aragão, “Separation of electromagnetic sources by the method of independent component analysis,” in *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC 2013)* Minneapolis, MN, EUA, May 6-9, 2013, pp. 476 – 479.
- [66] P. I. L. Ferreira, G. Fontgalland, and B. B. Albert, “Spread-out overlapping sources by independent component analysis for location positioning,” *IEEE Transactions on Magnetics*, vol. 49. No 5, May 2013, pp. 1805 – 1808.
- [67] G. Vinci, S. Lindner, F. Barbon, R. Weigel, and A. Koelpin, “Promise of a better position,” *IEEE Microwave Magazine*, vol. supplement, pp. S41 – S49, Nov./Dez. 2012.
- [68] The Laboratory of Information and Computer Science in the Helsinki University of Technology. The FastICA package for MATLAB. Disponível em:

<http://research.ics.aalto.fi/ica/fastica/code/dlcode.shtml>. Acessado em: 16/05/2011.

[69] J. Persson, “Methods of SNR estimation from asynchronously sampled data in an 802.11b system,” Master’s Thesis (Master in Signal Processing), Luleå University of Technology, 2004.

[70] J. Mitola III, *Software radio architecture: object-oriented approaches to wireless systems engineering*. New York: Third John Wiley & Sons, 1996.

[71] GNU Radio home page. Disponível em: <http://gnuradio.org/trac>. Acessado em: maio de 2013.

[72] Universal Software Radio Peripheral website. Disponível em: <http://www.ettus.com/>. Acessado em: maio de 2013.

[73] R. S. Babu and M. Suganthi, “Review of energy detection for spectrum sensing in various channels and its performance for cognitive radio applications,” *American Journal of Engineering and Applied Sciences (AJEAS)*, Science Publication, 2012, pp. 151 – 156.

[74] T. Yucek and H. Arslan, “A Survey of spectrum sensing algorithms for cognitive radio applications,” in *IEEE Communication Surveys and Tutorials*, vol. 11, N° 1, Jan. 2009, pp. 116 – 130.

[75] S. G. Mohapatra, A. G. Mohapatra, and Dr. S. K. Lenka, “Cyclostationarity based windowing method for spectrum sensing in cognitive radio networks,” *International Conference Information Communication and Embedded Systems (ICICES)*, Tamilnadu, India, 2013, pp. 603 – 608.

[76] H. Sun, A. Nallanathan, C.-X. Wang, and Y. Chen, “Wideband spectrum sensing for cognitive radio networks: a survey,” *IEEE Wireless Communications*, vol. 20, iss. 2, April 2013, pp. 74 – 81.

- [77] M. A. Abdulsattar and Z. A. Hussein, "Energy detection technique for spectrum sensing in cognitive radio: a survey," *International Journal of Computer Networks & Communications (IJCNC)*, vol.4. No 5, September 2012, pp. 223 – 242.
- [78] A. Hyvärinen, "Fast and robust fixed-point algorithms for independent component analysis," *IEEE Transactions on Neural Networks*, vol. 10. No 3, May 1999, pp. 626 – 634.
- [79] P. I. L. Ferreira, G. Fontgalland, B. B. Albert, and E. C. Gurjão, "Software-Defined Radio for spectrum sensing using independent component analysis," *The 14th International Conference on Advances in Cognitive Radio (COCORA 2014)*, February 23 -27, Nice, France, 2014, pp. 26 – 29.
- [80] Website Teleco – Inteligência em Telecomunicações. Disponível em: http://www.teleco.com.br/tutoriais/tutorialieeee1/pagina_3.asp. Acessado em: novembro de 2013.
- [81] D. Sant'Anna Chaves. "Análise do sensoriamento espectral por detecção de energia". Dissertação (Mestrado em Engenharia Elétrica), Universidade de Brasília – UNB, Brasília, 2012.
- [82] N. Han, S. H. Shon, J. H. Chung, and J. M. Kim, "Spectral correlation based signal detection method for spectrum sensing in IEEE 802.22 WRAN systems," *8th International Conference Advanced Communication Technology (ICTACT2006)*, Gangwon-Do, Republic of Korea, 2006, pp. 1765 – 1770.
- [83] A. B. Jemaa, M. Turki, and W. Guibène, "Enhanced energy detector via Algebraic approach for spectrum sensing in cognitive radio networks," in *7th International ICST Conference on Cognitive Radio Oriented Wireless Networks and Communications (CROWNCOM)*, Stockholm, Sweden, 2012, pp. 113 – 117.
- [84] C-H. Lee and W. Wolf, "Blind signal separation for cognitive radio," *Journal of Signal Processing Systems*, vol. 63, No. 1, April 2011, pp. 67 – 81.

[85] S. S. Ivriigh, S. M-S Sadough, and S. A. Ghorashi, “A blind source separation technique for spectrum sensing in cognitive radio networks based on kurtosis metric,” *International Conference on Computer and Knowledge Engineering (ICCKE2011)*, Oct. 13-14, Ferdowsi University of Mashhad, Mashhad, Iran, 2011, pp. 1 – 5.

[86] P. I. L. Ferreira, G. Fontgalland, B. B. Albert, and E. C. Gurjão, “TV Channel Spectrum Sensing Using Independent Component Analysis,” *submitted to IET Journal (The Institution of Engineering and Technology)*.

ANEXO A

AA – Algoritmo FastICA Desenvolvido no *Matlab*[®]

```

% GERAÇÃO DAS FONTES DE SINAIS ORIGINAIS, PARA SEPARAÇÃO E IDENTIFICAÇÃO
% USANDO O ICA
% os sinais são misturados dois a dois
% Id: testeICA_modificado2.m 07/11/2011 Paulo Ixtânio

close all
clc
clear

L = 10000;
N = 500; %tamanho dos dados
v = (0:N-1); % v=(0:L-1);
sig(1,:) = sin(v/2);
sig(2,:) = ((rem(v,27)-13)/9); %curva dente de serra
% sig(3,:) = ((rem(v,23)-11)/9).^5; %curva tipo tangente
% sig(4,:) = ((rand(1,N)<.5)*2-1).*log(rand(1,N)); %ruído impulsivo
subplot(4,1,1);
plot(sig(1,:), 'LineWidth',2);
title('Sinal Seno'), ylabel('Amplitude'), grid on
subplot(4,1,2);
plot(sig(2,:), 'LineWidth',2);
title('Sinal Dente de Serra'), ylabel('Amplitude'), grid on
subplot(4,1,3);
plot(sig(3,:), 'LineWidth',2);
title('Sinal tipo Tangente'), ylabel('Amplitude'), grid on
subplot(4,1,4);
plot(sig(4,:), 'LineWidth',2);
title('Sinal Ruído Impulsivo'), xlabel('Número de amostras'), ylabel('Amplitude'), grid on

fontes = [sig(1,:) ; sig(2,:)]; %fim = L; % matriz com os sinais
fontes.Equivalente ao vetor s

% NOTA IMPORTANTE: o comprimento das sequencias de entrada no FastICA
devem ser multiplos
% inteiros da variável janela.

M = rand(2); %Matriz de mistura aleatória A;

misturas = M*fontes; % duas misturas;

[separado1,separado2,W] =
func_fast_ica_modificado1(misturas(1,:),misturas(2,:),1000); %FastICA
janela = 1000

figure % fontes separadas ou seja, as componentes independentes.
plot(separado1,separado2,'k. ');
title('SINAIS ESTIMADOS: fonte estimada 1 X fonte estimada 2')

%W*M; %Teste de separação. A matriz de separação deve inverter a matriz
de mistura, a menos de permutação e escala.

% AVALIACAO DO GRAU DE SEMELHANCA ENTRE O SINAL ORIGINAL E O SINAL
ESTIMADO

```

```

coef_correlacao1 = corrcoef(sinal_gerado1,separado1)
coef_correlacao12 = corrcoef(sinal_gerado1,separado2)
% coef_correlacao2 = corrcoef(ruido_ambientel,separado2)
% coef_correlacao21 = corrcoef(ruido_ambientel,separado1)
% outros exemplos de fontes
% t = (0:0.01:40)*1e-3;
% s1 = (1 + 0.9*sin(300*pi*t)).*sin(3600*pi*t); % sinal AM com Fport =
1,8kHz, Fmod = 150Hz
% s2 = cos(2000*pi*t + 2*cos(200*pi*t));% sinal FM com Fport = 1 kHz,
Fmod = 100Hz

% FUNÇÃO FASTICA - RELIZA O ALGORITMO FASTICA PARA DUAS FONTES DE
ENTRADAS
% O PROGRAMA IMPLEMENTA AS TRÊS FUNÇÕES CUSTO, BASTANDO APENAS
% HABILITÁ-LAS.
% Id: func_fast_ica_modificado1.m 07/12/2011 Paulo Ixtânio

% Este código faz a ICA entre os sinais Entrada1 e Entrada2, obtendo
%duas componentes independentes Saidal e Saida2, utilizando o algoritmo
% FastICA com ortogonalização simétrica. Esse algoritmo é descrito em
% detalhes no livro "Independent Component analysis" (2001) de
%Hyvärinen,
% Karhunen e Oja, em especial na página 196 que mostra os passos do
% algoritmo do mesmo modo como está separado o código abaixo. Para a
% melhor estimativa de grandezas estatísticas os dados de entrada são
% processados em blocos do tamanho do parâmetro de entrada "janela". O
% desempenho deve ser comprometido se esse parâmetro for muito pequeno.

function [Saidal,Saida2,Wfinal] =
func_fast_ica_modificado1(Entrada1,Entrada2,janela)

L = length(Entrada1);

% passo 1: Centralizar os dados em zero

Rx_x_mz = Entrada1 - mean(Entrada1);
Rx_y_mz = Entrada2 - mean(Entrada2);

% passo 2: Branqueamento

% O processo de branqueamento visa a descorrelação dos sinais, que é um
% primeiro passo para a independência.

C = [0 0 ; 0 0];

for n = 1:L
    C = C + [Rx_x_mz(n) Rx_y_mz(n)]'*[Rx_x_mz(n) Rx_y_mz(n)];
end

C = C/L;

[E,D] = eig(C);

V = (D^(-1/2))*E';

Rx_x_bra = zeros(1,L);
Rx_y_bra = zeros(1,L);
for n = 1:L

```

```

    Rx_x_bra(n) = V(1,:) * [Rx_x_mz(n) Rx_y_mz(n)]';
    Rx_y_bra(n) = V(2,:) * [Rx_x_mz(n) Rx_y_mz(n)]';
end

% Passo 3 e 4 : Escolha inicial de W

% W é a matriz de separação, que aplicada às misturas recupera as
% fontes.
% Essa matriz pode ser encontrada de forma iterativa.

w1 = [1 0]';
w2 = [0 1]';

% Passo 5 e 6: Calculo de W

% A tarefa do FastICA é encontrar essa matriz. Observe que como os dados
% que serão submetidos ao ICA são as entradas branqueadas, são essas que
% devem ser multiplicadas por W quando este for encontrado.

for n = 1:janela:L %cada iteração usa um bloco do tamanho janela.

    A1 = [0 0]';
    B1 = 0;
    A2 = [0 0]';
    B2 = 0;

% O calculo do FastICA envolve submeter os dados à uma função
% não-linear não-quadrática e à sua derivada. Algumas funções são
% comuns no FastICA, como tanh e x^3, tanh(aly) e yexp(-y^2/2). A
% escolha da função tem alguma ligação com a distribuição das fontes.

    for k = 1:janela
        z = [Rx_x_bra(n+k-1) Rx_y_bra(n+k-1)]';
        A1 = A1 + z*(w1'*z)^3; % implementação da função custo y^3
        B1 = B1 + 3*(w1'*z)^2; % implementação da derivada 3y^2
        A2 = A2 + z*(w2'*z)^3;
        B2 = B2 + 3*(w2'*z)^2;

%         A1 = A1 + z*(tanh(w1'*z)); % implementação da função custo
tanh(aly)
%         B1 = B1 + (1 - (tanh(w1'*z)).^2); % implementação da derivada
(1 - tanh^2(aly))
%         A2 = A2 + z*(tanh(w2'*z));
%         B2 = B2 + (1 - (tanh(w2'*z)).^2);

%         A1 = A1 + z*(w1'*z).*exp(-(w1'*z).^2/2); % implementação da
função custo yexp(-y^2/2)
%         B1 = B1 + (1 - (w1'*z).^2).*exp(-(w1'*z).^2/2); %
implementação da derivada (1 - y.^2).*exp(-y.^2/2)
%         A2 = A2 + z*(w2'*z).*exp(-(w2'*z).^2/2);
%         B2 = B2 + (1 - (w2'*z).^2).*exp(-(w2'*z).^2/2);

    end

    A1 = A1/janela;
    B1 = B1/janela;
    A2 = A2/janela;
    B2 = B2/janela;

```

```

% O FastICA calcula linha por linha da matriz de separação.

w1 = A1 - B1*w1;
w2 = A2 - B2*w2;

% Essa é a matriz de separação obtida, mas falta a ortogonalização.

W = [w1' ; w2'];

% Procedimento de ortogonalização simétrica.

Wort = ((W*W')^(-1/2))*W;
dimensoes_Wort = size(Wort);
Produto_escalar = Wort'*Wort;
% Atualiza a matriz para a próxima iteração.

w1 = Wort(1,:);
w2 = Wort(2,:);
end

Saida1 = zeros(1,L);
Saida2 = zeros(1,L);

% Os sinais são recuperados ao multiplicar os dados branqueados pela
% matriz de separação.

for n = 1:L
    Saida1(n) = Wort(1,:)*[Rx_x_bra(n) Rx_y_bra(n)]';
    Saida2(n) = Wort(2,:)*[Rx_x_bra(n) Rx_y_bra(n)]';
end
    Wfinal = W*V;
end

% FUNÇÃO HISTOGRAMA - CALCULA O HISTOGRAMA DE UM CONJUNTO DE DADOS DE
% ENTRADA, PARA UM SENTIDO MAIS REALISTICO DOS RESULTADOS OS DADOS DE
% ENTRADA DEVEM SER GERADOS DE FORMA ALEATÓRIA
% Id: histograma.m,v 1.0 14/02/2011 Paulo Ixtânio

function histograma(X)
    %os limites das caixas do histograma devem ser calculados dessa forma

    minX = min(X);
    maxX = max(X);
    nbins = length(minX:0.2:maxX); % numero de caixas
    e = linspace(minX,maxX,nbins+1);
    H = histc(X,e);
    H(nbins) = H(nbins) + H(nbins+1); % explicado abaixo
    H = H(1:nbins); % redimensionando H
    bw = (maxX - minX)/nbins; % Largura das caixas
    a = e(1:nbins); % sequência do limite esquerdo
    b = e(2:nbins+1); % sequência do limite direito
    bin_centers = (a + b)/2; % centro da caixa
    n = length(X);
    Hnormalizado = H/(bw*n);
    bar(bin_centers,Hnormalizado,'hist') % histograma normalizado para
%fdp continua
end

```

AB – Ferramenta ICA Desenvolvida por Hyvärinen e Oja

A ferramenta desenvolvida por Hyvärinen e Oja foi feita em *Matlab*[®] e está disponível em [68]. A interface do programa está apresentada na Fig. AB. 1. O funcionamento do programa é relativamente simples, mas é preciso gerar os sinais misturados em outras rotinas e depois carregá-los usando o botão “*Load data*”, em seguida deve-se clicar no botão “*Do ICA*” para aplicar o algoritmo FastICA ao conjunto de misturas e obter as componentes independentes. Como o objetivo aqui não é explicar como a ferramenta funciona, deve-se procurar [68] para mais esclarecimentos.

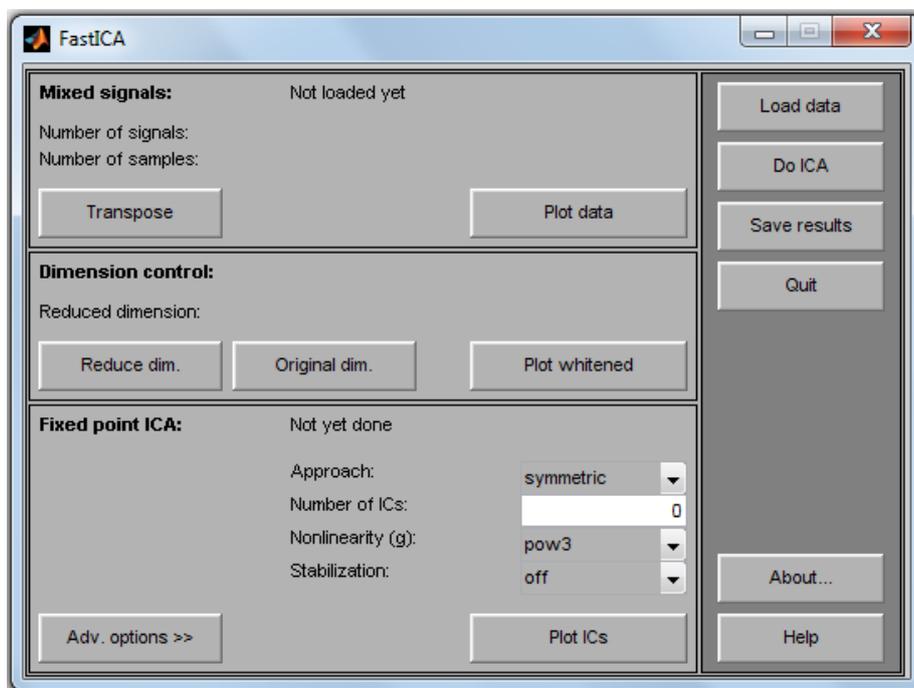


Figura AB 1 – Ferramenta para aplicar o algoritmo FastICA.

AC – Coeficiente de Reflexão das Antenas Log-Periódicas Planares

O parâmetro S_{11} de quatro antenas log-periódicas planares, pertencentes ao LAPS (Laboratório de Processamento de Sinais), será apresentado a seguir. As antenas compõem um quite de rádio definido por *software* utilizado nos experimentos do Capítulo 6.

O equipamento de medição usado no experimento foi o VNA – *Vector Network Analyzer* (Analisador de Redes Vetorial) da *R&S*, modelo ZVB 20 (10 MHz – 20 GHz).

As antenas foram denominadas de Antena 1, Antena 2, Antena 3 e Antena 4.

- Parâmetro S11 da Antena 1: log-periódica WA5VJB_1, 0,90 – 2,60 GHz

A antena apresenta o coeficiente de reflexão, numa faixa pouco maior que a faixa especificada pelo fabricante, tomando como referência o valor de -10 dB a largura de faixa é: 0,90 – 3,00 GHz. A maior ressonância ocorre em 1,323 GHz ($-44,52$ dB). Nas frequências usadas nos ensaios os valores do S11 são: em 1,20 GHz, S11 = -27 dB; em 1,40 GHz, S11 = -16 dB e; em 1,60 GHz, S11 = -19 dB. Portanto, as frequências desejadas estão bem abaixo do limiar de -10 dB.

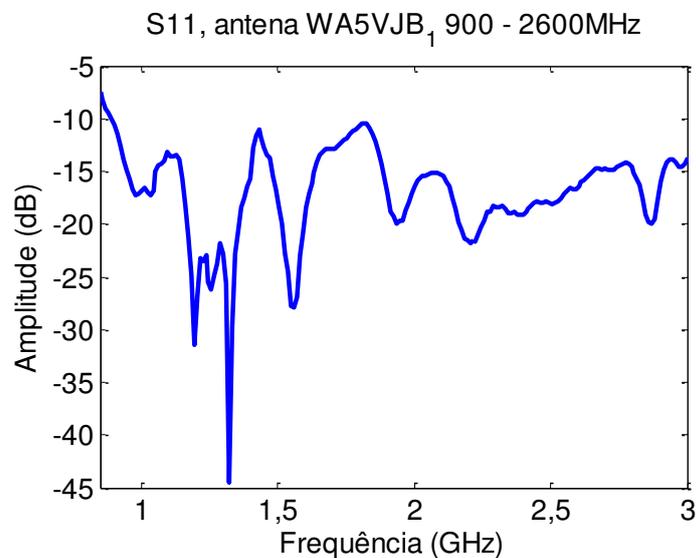


Figura AC 1 – Coeficiente de reflexão da Antena 1: log-periódica WA5VJB_1, 0,90 – 2,60 GHz.

- Parâmetro S11 da Antena 2: log-periódica WA5VJB_2, 0,90 – 2,60 GHz

Da mesma forma que a antena anterior o coeficiente de reflexão S11, está numa faixa pouco maior que a faixa especificada pelo fabricante, tomando como referência o valor de -10 dB. A largura de faixa é: 0,892 – 3,00 GHz. A maior ressonância ocorre em 1,323 GHz ($-30,22$ dB). Nas frequências usadas nos ensaios os valores do S11 são: em 1,20 GHz, S11 = $-23,93$ dB; em 1,40 GHz, S11 = $-14,78$ dB e; em 1,60 GHz S11 = -19 dB. Portanto, os níveis de atenuação são próximos da antena anterior.

De forma geral, as duas antenas possuem comportamentos parecidos na resposta do S11, porém com níveis de atenuação diferentes.

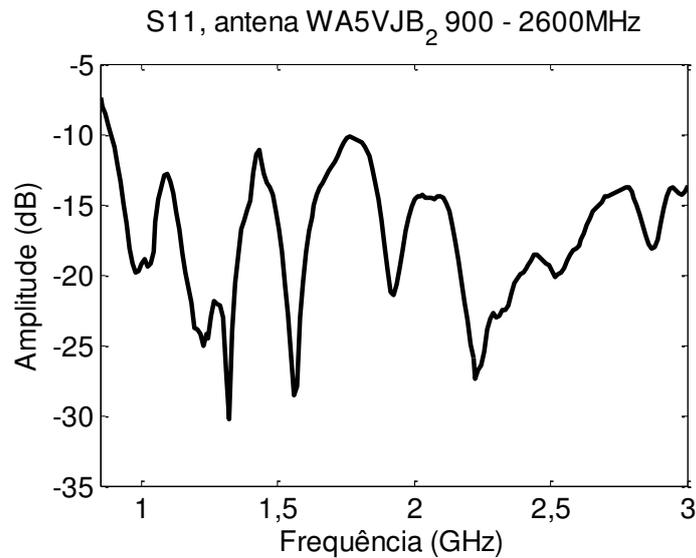


Figura AC 2 – Coeficiente de reflexão da Antena 2: log-periódica WA5VJB₂, 0,90 – 2,60 GHz.

- Parâmetro S11 da Antena 3: log-periódica WA5VJB₁, 0,85 – 6,50 GHz

O coeficiente de reflexão S11, desta antena está numa faixa menor que a faixa especificada pelo fabricante, tomando como referência o valor de – 10 dB, a faixa é: 0,90 – 4,58 GHz, mas dentro da faixa a ser usada. A maior ressonância ocorre em 1,88 GHz (–43,61 dB). Nas frequências usadas nos ensaios os valores do S11 são: em 1,20 GHz, S11 = –20,85 dB; em 1,40 GHz, S11 = –26 dB e; em 1,60 GHz, S11 = –12 dB.

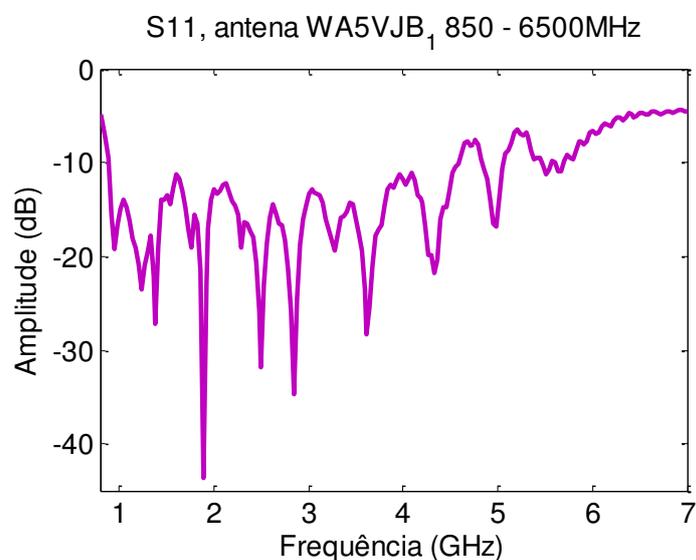


Figura AC 3 – Coeficiente de reflexão da Antena 1: log-periódica WA5VJB₁, 0,85 – 6,50 GHz.

- Parâmetro S11 da Antena 4: log-periódica WA5VJB_2, 0,85 – 6,50 GHz

A antena apresenta o coeficiente de reflexão S11, numa faixa menor que a faixa especificada pelo fabricante. Tomando como referência o valor de -10 dB, a faixa é: 0,905 – 5,08 GHz, mas dentro da faixa a ser usada. A maior ressonância ocorre em 2,51 GHz ($-36,52$ dB). Nas frequências usadas nos ensaios os valores do S11 são: em 1,20 GHz, S11 = $-21,6$ dB; em 1,40 GHz, S11 = $-21,6$ dB e; em 1,60 GHz, S11 = $-11,3$ dB. As duas antenas apresentam comportamentos parecidos, mas frequências de ressonâncias com atenuações diferentes, mesmo as duas antenas sendo do mesmo fabricante.

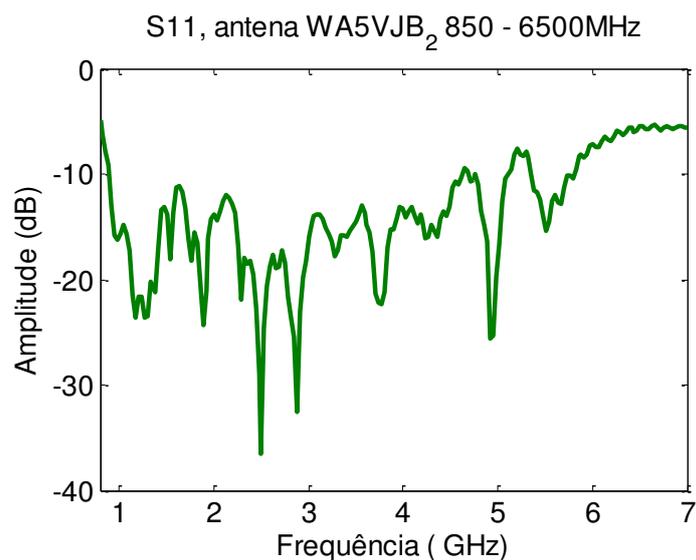


Figura AC 4 – Coeficiente de reflexão da Antena 2: log-periódica WA5VJB_2, 0,85 – 6,50 GHz.