

DANIEL MORAES SANTOS

**Redução de Ruído em Sensores de Monitoramento usando Separação
Cega de Fontes**

**UBERLÂNDIA
2016**

DANIEL MORAES SANTOS

**Redução de Ruído em Sensores de Monitoramento usando Separação
Cega de Fontes**

Tese apresentada ao Programa de Doutorado da Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia como requisito parcial à obtenção do título de Doutor em Ciências. Área de Concentração: Processamento Digital de Sinais.

Orientador: Prof. Dr. Antônio Cláudio
Paschoarelli Veiga

**UBERLÂNDIA
2016**

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

S237r Santos, Daniel Moraes.
2016 Redução de ruído em sensores de monitoramento usando separação
 cega de fontes / Daniel Moraes Santos. - 2016.
 235 f. : il.

 Orientador: Antônio Cláudio Paschoarelli Veiga.
 Tese (doutorado) - Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Elétrica.
 Inclui bibliografia.

 1. Engenharia elétrica - Teses. 2. Separação cega de fonte - Teses. 3.
Detectores - Teses. 4. Ruído elétrico - Teses. I. Veiga, Antônio Cláudio
Paschoarelli, 1963- II. Universidade Federal de Uberlândia. Programa
de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU: 621.3

“A mente que se abre a uma nova idéia
jamais voltará ao seu tamanho original...”

(Albert Einstein)

A meus pais,
Elizabeth (in memoriam)
e José Hely.

A meus Irmãos,
Mathews e Thiago.

Especialmente a Patrícia,
minha amada esposa e companheira
que me deu força e carinho nesta
caminhada, e a meus lindos filhos
Luca e Luna.

AGRADECIMENTOS

Ao meu Prof. Antônio Cláudio P. Veiga, meu orientador e amigo, que acreditou nessa proposta e se empenhou, ao meu lado, na sua elaboração. Pela dedicação, pelo profissionalismo e pelo apoio nos momentos mais difíceis, registro aqui a minha gratidão.

Aos colegas do doutorado, que em um determinado momento cruzaram meu caminho e com os quais pude contar, em especial ao colega Gustavo Nozella, que me auxiliou em vários momentos tirando algumas dúvidas e debatendo sobre vários temas.

Aos meus irmãos, Thiago e Mathews, pelo apoio nos dias de tristeza, sempre me incentivando, com palavras de atenção.

Ao meu pai, José Hely dos Santos, que mesmo nas situações difíceis da vida sempre esteve ao meu lado nesta caminhada.

A minha mãe pelo incentivo, acreditando sempre em minha capacidade, e também por se empenhar ao máximo no início dessa longa caminhada, mas prazerosa, lá atrás, na graduação.

A minha tão amada esposa, companheira e amiga, Patrícia Gonçalves de Marillac, pelo apoio incondicional e incentivo diário para que pudesse continuar esse caminho longo, mas gratificante. Pelos dias de tristeza, de angústias que ela com muita paciência e sabedoria soube contornar, e cada vez mais incentivar o término dessa longa e árdua caminhada.

Aos meus filhos queridos, Luca e Luna, que me fazem a cada dia querer ser uma pessoa melhor.

Finalmente, a todos aqueles que direta ou indiretamente caminharam ao meu lado e me incentivaram durante essa etapa.

SANTOS, Daniel Moraes. **Redução de Ruído em Sensores de Monitoramento usando Separação Cega de Fontes.** Uberlândia: Universidade Federal de Uberlândia MG, 2017. (Tese de Doutorado).

RESUMO

Separação Cega de Fonte (BSS) é conhecida por ser um processo eficiente e poderoso em separar e estimar sinais mutuamente independentes adquiridos por vários tipos de sensores de monitoramento.

Esses sensores de monitoramento captam sinais que são compostos por vários tipos de fontes, as fontes desejadas, as fontes indesejadas e as fontes ruidosas. Assim, o sinal desejado está comprometido para que possa ser analisado, isso pode levar a tomadas de decisões não eficientes. O ideal seria que os sinais analisados fossem compostos do maior nível de fontes desejadas, e menor nível de fontes indesejadas e fontes ruidosas.

Este trabalho propõe um algoritmo para identificar e reduzir os níveis de ruído em sinais monitorados por sensores usando Separação Cega de Fonte. Este algoritmo pode ser aplicado em várias áreas de monitoramento. Ele é capaz de identificar o ruído sem qualquer tipo de informação prévia do sinal analisado.

Inicialmente, o algoritmo realiza uma separação dos sinais que foram monitorados por sensores. Estes sinais podem ter sofrido influência (interferência) de seus sensores vizinhos. Diferentemente da BSS padrão, que requer pelo menos duas fontes, este algoritmo reduz os níveis de ruído de cada fonte separadamente aplicando os algoritmos de Taxa Máxima Sinal Ruído e Previsibilidade Temporal.

O algoritmo proposto também produz duas saídas para cada sinal (fonte), o sinal original estimado e o ruído estimado. Os resultados satisfazem todos os objetivos

proposto neste trabalho. Todas as métricas utilizadas como parâmetros (SNR – Relação Sinal Ruído, SDR – Relação Sinal Distorção e SIR – Relação Sinal Interferência) de avaliação dos resultados obtidos pelo algoritmo proposto foram satisfatórias. Em específico, para os dados de perfilagem térmica, os resultados mais interessantes foram os gradientes térmicos e seus respectivos desvios padrões, que apresentaram maior ganho de precisão.

Palavras – Chave: Separação Cega de Fonte, Análise Estatística, Sensores, Monitoramento, Análise de Componentes Independentes, Ruído, Previsibilidade Temporal, Taxa Máxima Sinal Ruído.

SANTOS, Daniel Moraes. **Redução de Ruído em Sensores de Monitoramento usando Separação Cega de Fontes**. Uberlândia: Universidade Federal de Uberlândia MG, 2017. (Tese de Doutorado).

ABSTRACT

Blind Source Separation (BSS) is known to be an efficient and powerful process to separate and estimate individual mutually independent signals acquired by various types of monitoring sensors.

Theses monitoring sensors capture signals that are composed of various types of sources, the desired sources, unwanted sources and noisy sources. Thus, the desired signal is compromised so that it can be analyzed, this can lead to inefficient decision making. Ideally, the analyzed signals should be composed of the higher level of desired sources, and lower level of unwanted sources and noisy sources.

This paper proposes an algorithm to identify and reduce noise in monitoring sensor signals using Blind Source Separation. This algorithm can be applied in any area of monitoring. It can identify noise without any kind of previous information of the signal analyzed.

Initially, the algorithm makes the separation of the signals that were acquired by the sensors. These signals may have suffered influence from several noise sources. Different from the standard BSS, which requires at least two sources, this algorithm removes the noise from each signal separately applying the Maximum Signal-to-Noise Ratio and Temporal Predictability algorithms.

The proposed algorithm also produces two outputs for each signal, the estimated original signal and the estimated noise. The results satisfy all the proposed objectives of this work. All the metrics used as parameters to evaluate the results obtained by the

proposed algorithm were satisfactory. Specifically, for the thermal profile data, the most interesting results were the thermal gradients and their respective standard deviations, which showed a significant improvement.

Key – Words: Blind Source Separation, Statistical Analysis, Sensors, Monitoring, Independent Component Analysis, Noise, Temporal Predictability, Maximum Signal Noise Ratio.

SANTOS, Daniel Moraes. **Redução de Ruído em Sensores de Monitoramento usando Separação Cega de Fontes**. Uberlandia: Universidad Federal de Uberlandia MG, 2017. (Tesis).

RESUMEN

Separación Ciega de Fuentes (BSS) es conocida por ser un procedimiento eficiente y poderoso para separar y estimar señales mutuamente independientes adquiridos por varios tipos de sensores de monitoreo.

Estos sensores de supervisión captan las señales que están compuestos de varios tipos de fuentes, las fuentes deseadas, fuentes no deseadas y las fuentes de ruido. Por lo tanto, la señal deseada se ve comprometida por lo que se puede analizar, esto puede conducir a la toma de decisiones ineficiente. Idealmente, las señales se analizaron los compuestos de la intensificación de los tipos de letra deseados y los niveles más bajos de fuentes no deseadas y las fuentes de ruido.

Este trabajo propone un algoritmo para identificar y reducir los niveles de ruido en señales monitorizadas por sensores utilizando la Separación Ciega de Fuentes. Este algoritmo puede ser aplicado a varias áreas de monitoreo. Él es capaz de identificar el ruido sin ninguna información previa de la señal analizada.

Inicialmente, el algoritmo realiza una separación de las señales que fueron monitorizadas por los sensores. Estas señales pueden haber sufrido influencia (interferencia) de sus sensores vecinos. Diferentemente de la BSS estándar, que quiere al menos dos fuentes, este algoritmo reduce los niveles de ruido de cada fuente separadamente aplicando los algoritmos de máximo de Tasa Máxima Señal Ruido y Previsibilidad Temporal.

El algoritmo propuesto también produce dos salidas para cada señal (fuente), la

señal original estimada y el ruido estimado. Los resultados satisfacen todos los objetivos propuestos en este trabajo. Todos los parámetros utilizados como parámetros para evaluar los resultados obtenidos por el algoritmo propuesto fueron satisfactorios. En particular, para los datos de perfiles térmicos, los resultados más interesantes tienen gradientes térmicos y su desviación estándar, que mostro una mejora significativa.

Palabras clave: Separación Ciega de Fuentes, Análisis Estadístico, Sensores, Monitoreo, Análisis de Componentes Independientes, Ruido, Previsibilidad Temporal, Tasa Máxima Señal Ruido.

Kurzzusammenfassung

Blindenquelletrennung (BSS) ist bekannt für ein wichtiges und überaus wirksames Verfahren zu trennen und zu schätzen unabhängige gegenseitige Signale durch verschiedene von Überwachungssensoren erworben werden.

Diese Überwachungssensoren holen signale, die von verschiedenen arten von quellen zusammengesetzt sind, die gewünschten schriftarten, unerwünschten quellen und larmquellen. Somit wird das gewünschte signal beeinträchtigt, so dass es analysiert werden kann, dies zu einer ineffizienten entscheidung führen kann. Idealerweise wurden die signale verbindungen der erhöhten niveau der gewünschten schriftarten und unteren ebenen von unerwünschten quellen und larmquellen analysiert.

Diese wissenschaftliche Arbeit schlägt einen Algorithmus vor um die Rauschpegel zu identifizieren und verringern in Signale von Verwendung der Blindenquelletrennung Sensoren überwacht werden. Dieser Algorithmus kann auf verschiedene Überwachung angewendet werden. Er kann den Rausch ohne vorher irgendeine Information der untersucht Signale identifizieren .

Anfänglich, der Algorithmus durchführt eine Trennung der Signale deren Sensore überwacht wurden . Diese Signale können Einfluss (Störstrahlung) von der Nachbarnsensoren bekommt haben. Anders als bei Standard BSS, wofür mindestens zwei Blindenquelletrennung, dieser Algorithmus reduziert die Rauschpegel von jede getrennt Quelle, unter die Algorithmen Höchstmass des Signal Rauschabstand und Zeitliche Vorhersehbarkeit.

Der vorgeschlagen Algorithmus produziert zwei Ausgängen für jede Signal

(Quelle), das geschätzt Originalsignal und das geschätzt Rauschabstand. Die Ergebniss erfüllen alles vorgeschlagene Ziele in diese Arbeit. Alle metriken als parameter verwendet, um die ergebnisse von dem vorgeschlagenen algorithmus erhalten zu bewerten waren zufriedenstellend. Insbesondere für den thermischen profilierungsdaten weisen die interessantesten ergebnisse warmegradienten und ihre standardabweichung, die eine signifikante verbesserung zeigten.

Schlüsselwörter: Blindenquellentrennung statistische Analyse, Sensoren, Überwachung, Analyse getrennte Komponenten, Lärm, Zeitliche Vorhersehbarkeit, Höchstmass Rauschsignal.

LISTA DE FIGURAS

Figura 2.1 - Extensômetro axial único [16].....	38
Figura 2.2 - Curva Característica Tensão x Deformação.....	41
Figura 2.3 - Deformação de um fio submetido a uma deformação elástica [27].....	42
Figura 2.4 - Ponte de Wheatstone [16].....	47
Figura 2.5 - Circuito quarto-de-ponte [16].....	50
Figura 2.6 - Montagem do extensômetro em quarto-de-ponte [12].....	50
Figura 2.7 - Circuito de meia-ponte [16].....	51
Figura 2.8 - Circuito meia-ponte diagonal [16].....	52
Figura 2.9 - Montagem do extensômetro em meia-ponte [16].....	53
Figura 2.10 - Circuito ponte completa [16].....	53
Figura 2.11 - Montagem do extensômetro em ponte completa [16].....	54
Figura 2.12 - Montagem do extensômetro a dois cabos em quarto-de-ponte [16].....	55
Figura 2.13 - Montagem do extensômetro a três cabos em quarto-de-ponte [16].....	56
Figura 2.14 - Comportamento da função densidade de probabilidade gaussiana com as variáveis: RMS, média e desvio padrão [31].....	60
Figura 2.15 - Função densidade de probabilidade gaussiana com desvio padrão $\delta = 1$ e $\delta = 3$ [37].....	62
Figura 2.16 - Execução da perfilagem de poço (desenho ilustrativo, sem escala) [34].....	65
Figura 2.17 - Variação da temperatura com a profundidade, considerando gradiente geotérmico de 25°C/km [36].....	67
Figura 3.1 - Modelo de mistura e separação da Análise de Componentes Independentes.....	73

Figura 3.2 - Funções de distribuição de probabilidade conjuntas de variáveis gaussianas e uniformes em um sistema de mistura instantânea [50].....	77
Figura 3.3 - Relação entre algoritmo, função custo e modelo para ICA.....	83
Figura 3.4 - Exemplos da f.d.p. gaussiana, sub-gaussiana e super-gaussiana [61].....	86
Figura 3.5 - Descrição geral separação cega de fontes [78].....	108
Figura 3.6 - Problema do processamento cego de sinais [9].....	110
Figura 4.1 - Arquitetura da BSS padrão (primeira etapa do algoritmo proposto).....	116
Figura 4.2 - Arquitetura do Algoritmo Proposto.....	117
Figura 4.3 - Diagrama de blocos do algoritmo proposto.....	118
Figura 4.4 - Fluxograma do Algoritmo de Previsibilidade Temporal.....	125
Figura 4.5 - Fluxograma do algoritmo Taxa Máxima Sinal Ruído.....	130
Figura 4.6 - Fluxograma da métrica relação sinal interferência (SIR).....	137
Figura 5.1 - Curva característica dos ensaios experimentais realizados pelo autor.....	145
Figura 5.2 - Classificação da tipologia das ligações de treliças planas devido à forma [11].....	147
Figura 5.3 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "T" [11].....	148
Figura 5.4 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "K" [11].....	148
Figura 5.5 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "KT" [11].....	148
Figura 5.6 - Ensaio prático selecionado por obter a correlação mais alta [11].....	149
Figura 5.7 - Sinal numérico correspondente ao ensaio prático da figura 4.6 [11].....	150
Figura 5.8 - Esquema do Equipamento de Perfilagem Térmica [10].....	153
Figura 5.9 - Perfilagem térmica da cidade de Camaçari - BA [10].....	156

Figura 5.10 - Perfilagem térmica da cidade de Nova Lima - MG [10].....	156
Figura 5.11 - Perfilagem térmica da cidade de Jaguarari - BA [10].....	157
Figura 5.12 - Sinal senoidal teórico com potência de 10 Watts.....	159
Figura 5.13 - Ruído teórico usando a função randn.....	160
Figura 5.14 - Sinal digital usado na modulação BPSK.....	161
Figura 5.15 - Sinal da portadora usado na modulação do sinal digital.....	162
Figura 5.16 - Sinal modulado usando BPSK.....	163
Figura 6.1 - Ruído detectado pelo algoritmo proposto do ensaio 1 da Tabela 5.1.....	165
Figura 6.2 - Sinais de entradas e estimados do ensaio 1(um) usando a técnica de relação máxima sinal ruído.....	166
Figura 6.3 - Perfilagem térmica estimada pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Camaçari – BA.....	170
Figura 6.4 - Perfilagem térmica estima pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Nova Lima – MG.....	171
Figura 6.5 - Perfilagem térmica estimada pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Jaguarari – BA.....	171
Figura 6.6 - Fluxograma de mistura dos sinais original, deslocado e ruído.....	174
Figura 6.7 - Sinal senoidal teórico com potência de 10 Watts.....	175
Figura 6.8 - Ruído gerado aleatoriamente com potência de 0,0983 Watt.....	176
Figura 6.9 - Sinal misturado 1 com potência de ruído igual 0.0983 Watt.....	176
Figura 6.10 - Sinal misturado 2 com potência de ruído igual 0.0983 Watt.....	177
Figura 6.11 - Sinal estimado para uma potência de ruído de 0,0983 Watt.....	177
Figura 6.12 - Relação potência de ruído por erro médio do sinal senoidal simples.....	179
Figura 6.13 - Sinal estimado para uma potência de ruído de 9,8298 Watts.....	179
Figura 6.14 - Sinal ruído com potência de 9,8298 Watts.....	180

Figura 6.15 - Diferença entre sinal original e sinal estimado para potência de ruído de 9,8298 Watts.....	180
Figura 6.16 - Sinal estimado para uma potência de ruído de 22,1171 Watts.....	181
Figura 6.17 - Sinal ruído com potência de 22,1171 Watts.....	182
Figura 6.18 - Diferença entre sinal original e sinal estimado para potência de ruído de 22,1171 Watts.....	182
Figura 6.19 - Relação potência de ruído por erro médio do sinal modulado usando BPSK.....	184
Figura 6.20 - Sinal modulado normalizado misturado 1 com potência de ruído de 0.104 Watt.....	185
Figura 6.21 - Sinal modulado normalizado misturado 2 com potência de ruído de 0.104 Watt.....	185
Figura 6.22 - Sinal ruído com potência de 0.104 Watt.....	186
Figura 6.23 - Sinal modulado estimado com potência de ruído de 0.104 Watt.....	186
Figura 6.24 - Sinal modulado normalizado misturado 1 com potência de ruído de 102.2641 Watts.....	187
Figura 6.25 - Sinal modulado normalizado misturado 2 com potência de ruído de 102.2641 Watts.....	187
Figura 6.26 - Sinal ruído com potência de 102.2641 Watts.....	188
Figura 6.27 - Sinal modulado estimado com potência de ruído de 102.2641 Watts.....	188
Figura 6.28 - Fluxograma do sistema de mistura 1 para múltiplos percursos.....	189
Figura 6.29 - Sinal modulado original com potência de 50 Watts.....	191
Figura 6.30 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	191
Figura 6.31 - Sinal modulado normalizado misturado 2 considerando sistema de mistura	

1 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	192
Figura 6.32 - Sinal modulado estimado considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	192
Figura 6.33 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt considerando sistema de mistura 1 para múltiplos percursos.....	193
Figura 6.34 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	194
Figura 6.35 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	194
Figura 6.36 - Sinal modulado estimado considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2146 Watts.....	195
Figura 6.37 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102.2146 Watts considerando sistema de mistura 1 para múltiplos percursos.....	195
Figura 6.38 - Fluxograma do sistema de mistura 2 para múltiplos percursos.....	197
Figura 6.39 - Sinal modulado original com potência de 50 Watts.....	199
Figura 6.40 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0999 Watt.....	199
Figura 6.41 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0999 Watt.....	200
Figura 6.42 - Sinal modulado estimado considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0999 Watt.....	201
Figura 6.43 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0999 Watt considerando sistema de mistura 2 para múltiplos	

percursos.....	202
Figura 6.44 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	203
Figura 6.45 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	203
Figura 6.46 - Sinal modulado estimado considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2146 Watts.....	204
Figura 6.47 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102.2146 Watts considerando sistema de mistura 2 para múltiplos percursos.....	205
Figura 6.48 - Fluxograma do sistema de mistura 3 para múltiplos percursos.....	207
Figura 6.49 - Sinal modulado original com potência de 50 Watts usado no sistema de mistura 3.....	209
Figura 6.50 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	209
Figura 6.51 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	210
Figura 6.52 - Sinal modulado estimado considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.....	210
Figura 6.53 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt considerando sistema de mistura 3 para múltiplos percursos.....	211
Figura 6.54 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	212
Figura 6.55 - Sinal modulado normalizado misturado 2 considerando sistema de mistura	

3 para múltiplos percursos com potência de ruído de 102.2641 Watts.....	212
Figura 6.56 - Sinal modulado estimado considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 102,2146 Watts.....	213
Figura 6.57 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102,2146 Watts considerando sistema de mistura 3 para múltiplos percursos.....	214
Figura 6.58 - Relação de potências estimadas para os sistemas de misturas 1, 2 e 3....	216
Figura 6.59 - Relação de erros médios dos sinais estimados para os sistemas de misturas 1, 2 e 3.....	217

LISTA DE TABELAS

Tabela 2.1 - Valores da sensibilidade à deformação de alguns materiais [25].....	46
Tabela 3.1 - Relação de valores de Kurtosis.....	85
Tabela 3.2 - Kurtosis x Tipo de variável Gaussiana.....	85
Tabela 3.3 - Determinação das variáveis através da negentropia.....	95
Tabela 5.1 - Relação da configuração dos ensaios e nível teórico de ruído.....	144
Tabela 6.1 - Relação da configuração dos ensaios, nível teórico de ruído e SNR usando a Relação Máxima Sinal Ruído.....	167
Tabela 6.2 - Porcentagens de convergências entre sinais experimentais e entre sinais apresentados pelo algoritmo proposto.....	168
Tabela 6.3 - Resultado dos valores das métricas de performance utilizando o algoritmo relação máxima sinal ruído e previsibilidade temporal.....	168
Tabela 6.4 - Convergência entre sinais experimental, numérico e BSS usando a relação máxima sinal ruído.....	169
Tabela 6.5 - Valores das medidas de performance para os dados experimental, numérico e algoritmo proposto.....	169
Tabela 6.6 - Valores dos Gradientes Térmicos e Desvios Padrões das Perfilagens Térmicas Originais [10].....	172
Tabela 6.7 - Valores dos gradientes térmicos e desvios padrões das perfilagens térmicas após tratamento pelo algoritmo proposto.....	172
Tabela 6.8 - Porcentagem entre gradientes térmicos e desvios padrões (algoritmo proposto e originais).....	173
Tabela 6.9 - Valores da métrica SIRI entre as perfilagens térmicas do algoritmo proposto e originais.....	173

Tabela 6.10 - Relação potência de ruído x potência do sinal estimado dos sinais teóricos.....	178
Tabela 6.11 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado.....	183
Tabela 6.12 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 1 para múltiplos percursos.....	190
Tabela 6.13 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 1.....	196
Tabela 6.14 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 2 para múltiplos percursos.....	198
Tabela 6.15 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 2.....	206
Tabela 6.16 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 3 para múltiplos percursos.....	208
Tabela 6.17 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 3.....	215

LISTA DE SIGLAS

BA – Bahia

BLISS – Aplicações e separação cega de fontes

BSS – Separação cega de fontes

BSP – Processamento cego de fontes

BPSK - Modulação por deslocamento de fase binária

CVL – Método convencional de gradiente

DC – Corrente contínua

EMG – eletromiografia

FA – Análises de fator

f.d.p. - Função densidade de probabilidade

GF – Fator Gage

HBM – Hottinger Baldwin Messtechnik

HOS – Estatística de ordem superior

ICA – Análise de componentes independentes

INFOMAX – Maximização da informação

MaxEnt – Maximização da entropia

MG – Minas Gerais

MLE – Estimativa de Máxima Verossimilhança

KLD – Divergência de Kullback-Leibler

PCA – Análise de componentes principais

RMS – Raiz do valor quadrático médio

SDR – Taxa sinal distorção

SHM – Monitoramento da saúde estrutural

SIR – Taxa sinal interferência

SIR^{IN} – Taxa sinal interferência de entrada

SIR^{OUT} – Taxa sinal interferência de saída

SNR – Taxa sinal ruído

v.a. – Variáveis aleatórias

SUMÁRIO

INTRODUÇÃO.....	29
1.1 Descrição do Sistema Proposto	33
1.2 Objetivos deste Trabalho	34
1.3 Justificativa deste Trabalho	34
1.4 Estrutura desta Tese	35
1.5 Considerações Finais deste Capítulo	35
CONCEITOS FUNDAMENTAIS.....	36
2.1 Extensometria	36
2.1.1 Extensômetro Elétrico de Resistência	37
2.1.1.1 Histórico da Extensometria	38
2.1.1.2 A Relação Tensão – Deformação (Lei de Hooke)	39
2.1.1.3 Princípios de Funcionamento	41
2.1.1.4 Circuito de Medição	46
2.1.1.4.1 Pontes de Wheatstone	46
2.1.1.5 Configurações dos Extensômetros.....	49
2.1.1.5.1 Circuito Quarto-de-Ponte	49
2.1.1.5.2 Circuito Meia-Ponte	51
2.1.1.5.3 Circuito Meia-Ponte Diagonal.....	52
2.1.1.5.4 Ponte Completa	53
2.1.1.6 Considerações Sobre os Extensômetros	54
2.1.1.6.1 Efeito da Temperatura.....	54
2.1.1.6.2 Efeito da Resistência dos Cabos.....	55
2.1.1.6.3 Sensibilidade Transversal	56
2.1.1.6.4 Alongamento Estático.....	56
2.1.1.6.5 Dissipação de Calor	57
2.1.1.6.6 Erros de Medição.....	57
2.2 Nível de Ruído Teórico.....	58
2.2.1 Introdução.....	58
2.2.2 Ruído Shot	58
2.2.3 Ruído Térmico	59
2.2.4 Análise Teórica do Ruído.....	60

2.3 Perfilagem Geofísica	63
2.3.1 Princípio do Método Geotérmico	66
2.4 Considerações Finais deste Capítulo	67
ANÁLISE DE COMPONENTES INDEPENDENTES E SEPARAÇÃO CEGA DE FONTES	68
3.1 Análise de Componentes Independentes (ICA).....	68
3.1.1 Histórico da ICA.....	69
3.1.2 Condições de Contorno da ICA.....	71
3.1.3 Premissas do Modelo.....	73
3.1.3.1 Independência Estatística	73
3.1.3.2 Variáveis Não Gaussianas.....	75
3.1.4 Ambiguidades da ICA	77
3.1.5 Técnicas de Pré – Processamento	79
3.1.5.1 Centralização	79
3.1.5.2 Branqueamento	80
3.1.6 Princípios para Estimativa de Componentes Individuais	82
3.1.6.1 Maximização da Não Gaussianidade.....	83
3.1.6.1.1 Medida de Não Gaussianidade por Kurtosis	84
3.1.6.1.2 Entropia e Informação Mútua.....	88
3.1.6.1.3 Divergência de Kullback-Leibler	90
3.1.6.1.4 Negentropia	93
3.1.6.1.5 Aproximação da Negentropia	95
3.1.6.2 Princípio de MaxEnt e InfoMax	97
3.1.6.3 Estimativa de Máxima Verossimilhança.....	101
3.2 Análise de Componentes Principais	105
3.3 Separação Cega de Fontes (<i>BSS – Blind Source Separation</i>).....	106
3.3.1 Introdução da BSS	107
3.3.2 Histórico da BSS	108
3.3.3 Definição do Problema da BSS	110
3.4 Considerações Finais deste Capítulo	111
ALGORITMO PROPOSTO	112
4.1 Introdução.....	112
4.2 Arquitetura do Algoritmo Proposto	115
4.2.1 Estrutura Organizacional do Algoritmo Proposto	117
4.3 Algoritmos de Análise da BSS	120

4.3.1 Algoritmo de Previsibilidade Temporal.....	120
4.3.1.1 Estrutura Organizacional do Algoritmo de Previsibilidade Temporal..	125
4.3.2 Algoritmo Taxa Máxima Sinal Ruído.....	126
4.3.2.1 Estrutura Organizacional do Algoritmo Taxa Máxima Sinal Ruído.....	129
4.4 Métricas de Avaliação.....	131
4.4.1 Relação Sinal Ruído (SNR) e Relação Sinal Distorção (SDR).....	131
4.4.1.1 Decomposição de Fontes Estimadas por Projeções Ortogonais.....	132
4.4.1.2 Da Decomposição de Fontes Estimadas para Medidas de Performance Global	134
4.4.2 Relação Sinal Interferência (SIR).....	135
4.4.2.1 Estrutura Organizacional da Métrica Relação Sinal Interferência (SIR)	137
4.5 Considerações Finais deste Capítulo	140
SINAIS ANALISADOS	141
5.1 Ensaio Prático com Extensômetros	141
5.1.1 Introdução.....	141
5.1.2 Protótipo da Estrutura de Análise dos Extensômetros.....	142
5.1.3 Sinais Analisados.....	143
5.2 Modelo Experimental e Numérico	145
5.2.1 Introdução.....	145
5.2.2 Ensaio Prático	147
5.2.3 Sinais Analisados.....	149
5.3 Ensaio Prático com Sondas Térmicas.....	150
5.3.1 Introdução.....	150
5.3.2 Protótipo da Sonda de Perfilagem	152
5.3.3 Calibração do Equipamento de Perfilagem Térmica	153
5.3.4 Gradientes Geotérmicos e Método Convencional (CVL)	154
5.3.5 Sinais Analisados.....	155
5.4 Sinais Teóricos.....	157
5.4.1 Introdução.....	157
5.4.2 Sinais Analisados.....	158
5.4.2.1 Sinal Senoidal Simples	159
5.4.2.2 Sinal Modulado usando BPSK	160
5.4.2.3 Sinal Modulado usando BPSK para Múltiplos Percursos	163
5.4.2.3.1 Múltiplos Percursos	163
5.5 Considerações Finais deste Capítulo	164
RESULTADOS OBTIDOS	165

6.1 Resultados do Ensaio Prático com Extensômetros.....	165
6.2 Resultados do Modelo Experimental e Numérico	169
6.3 Resultados do Ensaio Prático com Sondas Térmicas	170
6.4 Resultados dos Sinais Teóricos.....	174
6.4.1 Sinal Senoidal Simples	174
6.4.2 Sinal Modulado usando BPSK	183
6.4.3 Sinal Modulado usando BPSK para Múltiplos Percursos	188
6.4.3.1 Múltiplos Percursos - Mistura 1	189
6.4.3.2 Múltiplos Percursos - Mistura 2	197
6.4.3.3 Múltiplos Percursos - Mistura 3	206
6.4.3.3.1 Análise Comparativa entre os Três Tipos de Misturas	215
6.5 Considerações Finais deste Capítulo	217
CONCLUSÕES	219
7.1 Análise dos Resultados Obtidos	219
7.2 Contribuições do Trabalho	222
7.3 Sugestões para Trabalhos Futuros	223
BIBLIOGRAFIA	224

CAPÍTULO 1

INTRODUÇÃO

Durante os últimos anos, houve um grande crescimento em várias áreas, por exemplo, na construção civil¹ [1, 2], em biomedicina² e geofísica³ [3], tanto mundial quanto no Brasil. Com isso, houve também uma demanda muito grande em estudos e pesquisas, tanto de técnicas quanto de equipamentos, aplicados nestas áreas. Um tópico em especial, que as pesquisas têm se desenvolvido consideravelmente, é no seguimento de monitoramento de sinais.

Esta pesquisa utilizou sinais monitorados em duas áreas de aplicações, a construção civil e a geofísica. Na primeira área, serão analisados sinais aplicados em monitoramento de estruturas civis (SHM – *Structural Health Monitoring*) e na segunda, sinais de monitoramento de sondas térmicas para caracterização de perfilagem térmica.

Quando se constrói uma estrutura, na maioria das vezes, não se sabe ao certo até quando esta será necessária, útil ou ainda o mais importante, segura. No projeto utilizam-se características conhecidas dos materiais, como resistência à compressão, resistência a ataques químicos e a intempéries, além de expectativas de carregamento e condições de exposição em uso. Porém, as reais interações entre a estrutura e o ambiente no qual ela está inserida são difíceis de prever ou simular. Além do carregamento em uso, que pode variar de forma diferente do previsto (incremento de tráfego sobre uma ponte ou modificação de uso de um edifício, por exemplo), outras questões são as sobrecargas acidentais, como terremotos, inundações, etc. Todas estas incertezas fazem com que uma previsão precisa da degradação da estrutura ao longo do

¹ Termo que engloba a confecção de obras como casas, edifícios, pontes, barragens, fundações de máquinas, estradas, aeroportos e outras infraestruturas.

² Ciência que atua no campo de interface entre Biologia e Medicina.

³ É o estudo da estrutura, da composição, das propriedades físicas e dos processos dinâmicos da Terra.

tempo seja muito complexa. Para confirmar a segurança e a fidelidade da estrutura em relação ao projeto são feitas inspeções, que avaliam a degradação, a segurança e as condições gerais da estrutura [1].

O conceito de monitoramento estrutural já era conhecido e utilizado principalmente na indústria aeronáutica e mecânica, mas foi no início dos anos 90 que o monitoramento estrutural ou SHM começou um desenvolvimento considerável na área da construção civil. A partir disso, vários centros de pesquisas neste campo de conhecimento (engenharia civil) tornou o tema (SHM) uma nova especialidade da engenharia [1].

Atualmente, é muito utilizado esse tipo de monitoramento (SHM) devido seus inúmeros benefícios, além da segurança, como projetos e construções de estruturas civis, mais especificamente de pontes com vida útil superior a 100 anos. Quando se começa a pensar em construir estruturas civis para mais de 100 anos de vida útil, é necessário inserir uma nova filosofia, integrando as várias fases da obra, desde o projeto até a fase de serviço, em termos de durabilidade, e uma dessas fases é o monitoramento dessas estruturas [4].

Uma definição simples e direta para monitoramento é uma sequência de observações ou mensurações sistemáticas devidamente registradas e acompanhadas de avaliação. No caso do monitoramento estrutural, parâmetros relativos à condição e desempenho da estrutura são observados, gravados e avaliados com o intuito de fornecer de forma precisa e ágil a situação na qual a estrutura se encontra. O monitoramento estrutural pode ser considerado uma ferramenta e pode ser usada para aumentar a segurança, durabilidade e otimização de manutenção de estruturas [1].

Graças ao monitoramento ao longo do tempo, que permite considerar o histórico completo da estrutura, é possível também a composição de um prognóstico (evolução

do dano, vida útil residual, etc.) [5].

Existem vários problemas e limitações no desenvolvimento de sistemas de monitoramento de estruturas civis. As direções em desenvolvimentos e pesquisas em SHM têm como objetivo dimensionar sistemas autônomos para monitorar as estruturas mantendo-as seguras e eficientes. É possível citar alguns destes problemas e limitações, como, a confiabilidade do sistema, instrumentação inapropriada e sensores sobrecarregados, armazenamento de dados e dados sobrecarregados, comunicações, mineração de dados e apresentação da informação, e fatores ambientais e ruído⁴ [6].

Este último ponto, fatores ambientais e ruído, principalmente o ruído, não é somente limitação na área de monitoramento de estruturas civis, mas em qualquer área de aquisição de dados através de sensores, tanto na engenharia civil, na engenharia elétrica, ou em qualquer engenharia. Sinais de sensores podem trabalhar em condições controladas, mas, como muitos trabalhos em estruturas de grande escala têm demonstrado alterações nas propriedades modais devido a condições ambientais, e a mistura de ruído, reduzindo a probabilidade de detecção de danos reais [6].

Na área de geofísica, serão estudados sinais utilizados para representar o perfil de poços, também conhecido como perfilagem. O perfil de poço é a prática de efetuar um registro detalhado das formações geológicas atravessadas por uma perfuração. Existem várias grandezas que podem ser utilizadas para realizar essa perfilagem, nesta pesquisa serão analisados sinais térmicos, chamada de perfilagem térmica.

Os procedimentos de SHM e a perfilagem térmica obterão sucesso se utilizarem meios para compensar ou filtrar os efeitos ambientais e ruídos, ou pelo menos, estabelecer níveis de confiança para detecção de anomalias contra o ruído [7]. Sendo assim, vários métodos e técnicas de tratamento e retirada de ruído são estudados, a

⁴ Qualquer flutuação não intencional que aparece no topo do sinal medido.

maioria baseado em filtragem⁵.

Este trabalho tem como foco o problema do ruído presente nos sinais monitorados. O objetivo é desenvolver um algoritmo que pode ser aplicado em situações gerais, detectando e reduzindo os níveis de ruído nos sinais monitorados. Existem muitas áreas de aplicação para esse tipo de algoritmo, por isso o ideal é que fosse desenvolvido de modo genérico. Deste modo pode ser aplicado em várias áreas sem a necessidade de estabelecer parâmetros dos dados de entrada. Isto o qualifica como um algoritmo extremamente prático.

Uma vez, que todos os sinais monitorados por sensores (qualquer tipo de sensor) captam não somente os sinais desejados, mas também, sinais de fontes indesejadas, bem como sinais de fontes ruidosas. Para que seja possível realizar uma tomada de decisão eficiente é necessário a redução dos níveis de ruídos, e também retirar os sinais de fontes indesejadas.

Para desenvolver este algoritmo algumas técnicas associadas a esse tipo de problema (ruído) foram analisadas. Para conter todas as características citadas foi estabelecida como ferramenta de trabalho uma técnica baseada puramente na análise estatística do sinal.

A BSS (*Blind Source Separation*) ou separação cega de fontes, recentemente, tem recebido atenção nos campos de processamento de sinais e redes neurais por causa do seu potencial em várias aplicações, como, comunicação wireless, reconhecimento da fala, processamento de sinais biomédicos [8]. Como essa técnica é aplicada em sinais das áreas mais importantes das engenharias, este trabalho realizou sua aplicação nos sinais de monitoramento de estruturas civis e caracterização de perfilagem térmica.

A BSS processa e analisa os dados, com o objetivo de recuperar, reconhecer ou

⁵ Método utilizado para separação de componentes.

separar fontes desconhecidas a partir unicamente dos sinais observados, obtidos por um conjunto de sensores [9]. Não necessitando de nenhum parâmetro ou modelagem de entrada dos dados, tornando assim uma ferramenta muito poderosa para tais atividades.

1.1 Descrição do Sistema Proposto

O objetivo principal deste trabalho é desenvolver um algoritmo baseado na técnica BSS (*Blind Source Separation*) para reduzir os níveis de ruído, que possa ser aplicado em sinais monitorados de várias áreas, não necessitando de parâmetros dos sinais de entrada.

Foram utilizados dois algoritmos da BSS para realizar os testes nos sinais monitorados: Taxa Máxima Sinal Ruído e Previsibilidade Temporal. Para esses algoritmos foi considerada uma análise de misturas instantâneas. Uma análise de misturas convolucionais foi aplicada apenas no algoritmo Taxa Máxima Sinal Ruído.

Como técnicas de comprovação dos resultados determinados pelo algoritmo proposto foram utilizadas algumas métricas, como a taxa sinal-distorção (*SDR – Signal-Distortion Ratio*), a taxa sinal-ruído (*SNR – Signal-to-Noise Ratio*) e taxa sinal-interferência (*SIR – Signal Interference Ratio*).

Os sinais analisados pelo algoritmo proposto advêm de aplicações distintas, a primeira foi a utilização de extensômetros resistivos em experimentos práticos para monitoramento das possíveis variações apresentadas pelas estruturas analisadas. A segunda aplicação foi a análise de sinais monitorados por sondas térmicas, caracterizando a perfilagem térmica de poços [10]. A terceira aplicação foi com a utilização de sinais de um experimento prático utilizando extensômetros e seu sinal correspondente gerado através de um modelo numérico (utilizando elementos finitos)

[11]. Por último, sinais gerados teoricamente pelo software Matlab⁶ utilizando cálculo de potência dos sinais e potência de ruídos.

1.2 Objetivos deste Trabalho

Essa pesquisa tem como objetivo desenvolver um algoritmo que seja capaz de realizar todas as funcionalidades abaixo:

- Reduzir níveis de ruído presentes em sinais monitorados;
- Aplicação ampla e geral, que possa ser aplicado em qualquer tipo de sinal analisado;
- Não necessite de nenhum parâmetro de entrada ou conhecimento a priori do sinal analisado;
- Analise os sinais monitorados apenas em nível estatístico sem a utilização de elementos ativos;
- Apresente uma baixa complexidade computacional;
- Apresente-se como uma técnica de redução de ruído eficiente para qualquer aplicação.

1.3 Justificativa deste Trabalho

Este trabalho se justifica pela crescente demanda, no cenário atual, por técnicas eficientes de análise e monitoramento de sinais em várias áreas de aplicação. Técnicas que apresente realmente os sinais mais próximos do real, ou seja, cada vez mais reduzindo todos os tipos de ruídos que possam estar inseridos nos sinais analisados.

Essa crescente demanda é realidade, por exemplo, no monitoramento de

⁶ Software interativo de alta performance voltado para o cálculo numérico, desenvolvido por Mathworks.

estruturas civis, mais precisamente em análise de patologias⁷ estruturais. Outra área que se justifica esta pesquisa é em caracterização de perfis de poços.

1.4 Estrutura desta Tese

Os capítulos 2 e 3 apresentam a fundamentação teórica na qual a elaboração do algoritmo proposto teve como base. O capítulo 2 trata os conceitos fundamentais referentes a extensometria, a caracterização dos níveis de ruídos teóricos e as teoria da perfilagem geofísica.

O capítulo 3 especifica cada área de conhecimento pertinente para a construção eficiente deste trabalho, como: Ruído, Análise de Componentes Independentes (*ICA – Independent Component Analyze*), Análise de Componentes Principais (*PCA – Principal Component Analyze*) e Separação Cega de Fontes (*BSS – Blind Source Separation*).

O capítulo 4 descreve detalhadamente o algoritmo proposto neste trabalho, bem como os algoritmos e métricas utilizados.

O capítulo 5 mostra os sinais utilizados nas análises do algoritmo proposto.

O capítulo 6 descreve os resultados obtidos após aplicação do algoritmo proposto nos sinais analisados.

O capítulo 7 apresenta as conclusões, as contribuições deste trabalho e as sugestões para trabalhos futuros.

1.5 Considerações Finais deste Capítulo

Este capítulo mostrou a proposta, os objetivos, a justificativa e a estrutura do trabalho.

⁷ Significa “estudo da doença”, na construção civil pode-se atribuir patologia aos estudos dos danos ocorridos em edificações.

CAPÍTULO 2

CONCEITOS FUNDAMENTAIS

Este capítulo apresenta a fundamentação teórica dos temas predominantes da primeira parte desta tese. Inicialmente, é introduzido o fundamento de extensometria, logo depois realiza um estudo sobre a teoria de níveis de ruídos, e no final realiza a caracterização teórica de perfilagem geofísica.

2.1 Extensometria

A extensometria é uma técnica experimental para a medição de esforços e deformações baseando-se na mudança da resistência elétrica de um material ao ser submetido a tensões [12]. É muito ampla a área de aplicação da extensometria nos mais diversos campos das engenharias, e os fabricantes oferecem uma quantidade enorme de modelos para atender às mais diversas demandas do mercado, que variam em função da aplicação [12]. Especificar o modelo do extensômetro a ser utilizado em uma determinada aplicação não é uma tarefa trivial. Uma escolha acertada requer muito conhecimento de vários aspectos relacionados ao objetivo da aplicação, ao processo de medição e aos materiais usados [13].

Existem vários tipos de extensômetros: resistivos, semi-condutores, vapor-depositado, capacitivos, piezoelétricos e fotoelásticos [14]. Neste trabalho serão descritas as características apenas dos extensômetros resistivos.

2.1.1 Extensômetro Elétrico de Resistência

Desde 1940, o extensômetro resistivo (*resistive strain gage*) tem sido a ferramenta mais comumente utilizada na análise experimental de tensão⁸ e deformação⁹. Isto porque este equipamento é muito preciso, tem uma sensibilidade muito grande, é versátil e a sua utilização é muito fácil, em comparação a outros sensores disponíveis para tal fim [15].

A facilidade de manipulação e sua capacidade de monitorar deformações até as cargas finais de ensaio, tornam o extensômetro ainda mais ampla sua utilização [12].

O nome extensômetro significa medidor de deformação e o nome extensômetro de resistência elétrica (que por ser simplificado, neste trabalho será chamado apenas de extensômetro) significa medidor de deformação (mecânica) relativa através da determinação da variação da resistência elétrica.

O extensômetro elétrico é um equipamento sensível que converte pequenas variações de dimensões em variações equivalentes de sua resistência elétrica. Sua utilização constitui um meio de se medir e registrar o fenômeno da deformação como uma grandeza elétrica [12].

Existem vários tipos de tecnologias de fabricação dos extensômetros resistivos, entre eles os extensômetros do tipo folha ou lâmina, fabricado com dois elementos: a base e a grade. Estes são diferenciados entre si, principalmente pelo formato e o tamanho de grade [16].

⁸ Medida de força interna por unidade de área de um corpo deformável em uma superfície imaginária interna ao corpo.

⁹ Mudança da configuração geométrica do corpo que leve a uma variação da sua forma ou das suas dimensões após a aplicação de uma ação externa.

O extensômetro resistivo pode ser usado como ferramenta em várias análises experimentais de tensão e deformação, este instrumento é um dos equipamentos mais precisos que existe nesta área [12, 17]. Este tipo de sensor foi escolhido por sua grande precisão, como dito anteriormente, assim existe níveis muito pequenos de ruídos presentes nos sinais captados. Por isso, o extensômetro é um instrumento aplicado em várias áreas, como construção, aeroespacial, biomedicina, entre outras [18, 19, 20, 21].

Entretanto, como qualquer sensor, também capta múltiplos níveis de ruído, como ruído de temperatura, ruído gaussiano, entre outros [21, 22, 23].

Neste trabalho, para realização dos experimentos práticos, utilizou-se extensômetros do tipo folha, mais especificamente, o extensômetro axial único ilustrado na Figura 2.1. Este tipo de extensômetro é utilizado para medir deformações em um único sentido.




Figura 2.1 - Extensômetro axial único [16].

2.1.1.1 Histórico da Extensometria

Willian Thomsom, por volta de 1856, foi quem iniciou o desenvolvimento da extensometria. Lord Kelvin, como também era conhecido, realizou experimentos práticos utilizando cobre e ferro para averiguar que a resistência elétrica desses

materiais variava conforme a deformação que a estrutura apresentava. Mas foi Roy Carlson, entre 1930 e 1940, que realmente desenvolveu o princípio do extensômetro de fio livre, que ainda são utilizados atualmente em transdutores de pressão, aceleração, torção entre outros, por sua excelente estabilidade [14, 15].

A primeira aparição do extensômetro com a configuração inicial que é utilizada atualmente foi aplicada no final da década de 30 por Edward Simmnos (*Califórnia Institute of Technology – Pasadena, CA, USA*) e por Arthur Ruge (*Massachusetts Institute of Technology – Cambridge, MA, USA*). Ambos realizaram os trabalhos simultaneamente, porém individuais. Simmons desenvolveu um dispositivo para mensurar a força de impacto de um pêndulo em corpo de prova. Ruge criou um sensor para medir as deformações em simulações de terremotos [14, 15].

Com o rápido avanço da indústria aeronáutica devido à 2ª Guerra Mundial, houve um avanço muito grande nas pesquisas de técnicas de utilização de fios resistivos em estruturas. Foi nesta situação que se deu o desenvolvimento do extensômetro de folha fina (*foil type strain gage*) em 1952 [24].

A partir de então, diversos tipos de extensômetros foram e têm sido desenvolvidos, sendo escopo de diversas pesquisas pelo mundo [12]. Com a crescente evolução da construção civil, houve uma preocupação em desenvolver extensômetros para aplicar no monitoramento de estruturas civis.

2.1.1.2 A Relação Tensão – Deformação (Lei de Hooke)

Quando um dado material é tracionado, a força aplicada ao material é proporcional à deformação causada na região elástica, ou seja, mantendo uma relação constante entre a força externa e a deformação.

Isto implica no fato de que a força para contrabalançar a ação externa é gerada internamente no material, e a magnitude de força por unidade de área é chamada de tensão [25].

Normalmente os materiais possuem a propriedade de se esticar quando tracionados e de se encolher quando comprimidos. Considera-se a seguinte situação onde um material é tracionado, e a quantidade de alongamento seja considerada por ΔL , e o comprimento original seja L . A proporção de alongamento $\Delta L/L$ é conhecida por deformação e é adimensional¹⁰.

$$\varepsilon = \frac{\Delta L}{L} \quad (2.1)$$

A Figura 2.2 especifica a relação característica entre tensão e deformação de um corpo de aço doce submetido a um carregamento de tração. Da origem ao ponto a , a tensão é proporcional à deformação, verificando uma linearidade entre as variáveis. Esta área é conhecida como região elástica, onde se aplicam as leis de Hooke.

¹⁰ É um número desprovido de qualquer unidade física que o defina, portanto é um número puro.




Figura 2.2 - Curva Característica Tensão x Deformação [25].

A relação tensão – deformação na região elástica é dada pela equação abaixo:

$$\frac{\sigma}{\varepsilon} = E \quad (2.2)$$

Onde E é uma constante de proporcionalidade, a qual é referida como módulo de elasticidade longitudinal ou módulo de Young [25].

2.1.1.3 Princípios de Funcionamento

Em 1856, Kelvin comprovou que a resistência elétrica de um fio (cobre ou ferro) varia ao ser submetido a uma deformação elástica [26]. A Figura 2.3 demonstra esse efeito.




Figura 2.3 - Deformação de um fio submetido a uma deformação elástica [27].

Com isso, um fio de resistência R e com comprimento L sofre uma deformação elástica igual a ΔL , de forma análoga a resistência também sofre uma variação (acrécimo) ΔR . A relação entre as variações relativas $\Delta R/R$ e $\Delta L/L$ se dá de forma linear. A equação abaixo demonstra essa relação:

$$k = \frac{\Delta R/R}{\Delta L/L}. \quad (2.3)$$

Essa relação é constante se a deformação acontece na região elástica do material. O fator K é a sensibilidade do extensômetro, muito conhecido pelo seu nome original em inglês, *Gage Factor* (GF) [16].

Analisando a sensibilidade do extensômetro (K) pode-se estimar uma equação geral para ele. Considera-se um fio de comprimento L , área A , resistividade ρ , diâmetro D e coeficiente de Poisson¹¹ ν . A equação da resistência R é dada por:

$$R = \frac{\rho L}{A} \quad (2.4)$$

¹¹ Mede a deformação transversal de um material homogêneo e isotrópico.

Fazendo $A = \pi D^2/4$, ou seja, considerando um fio condutor cilíndrico. Assim,

$$R = \rho \left[\frac{4}{\pi D^2} \right] L \quad (2.5)$$

Fisicamente, a grade do extensômetro sofre pequenas alterações quando o material ao qual está fixado é comprimido ou alongado [28]. A alteração da resistência é dada por:

$$dR = \frac{\partial R}{\partial \rho} d\rho + \frac{\partial R}{\partial D} dD + \frac{\partial R}{\partial L} dL \quad (2.6)$$

Resolvendo as derivadas parciais,

$$\frac{\partial R}{\partial \rho} = \frac{4}{\pi D^2} L, \frac{\partial R}{\partial D} = -\frac{8\rho L}{\pi D^3} \text{ e } \frac{\partial R}{\partial L} = \frac{4\rho}{\pi D^2}$$

Assim,

$$\frac{dR}{R} = \frac{dL}{L} - 2 \frac{dD}{D} + \frac{d\rho}{\rho} \quad (2.7)$$

Considerando,

$$\frac{dD}{D} = -\nu \frac{dL}{L} \quad (2.8)$$

Onde ν é o coeficiente de Poisson. Com isso a Equação 2.7 pode ser escrita como:

$$\frac{dR}{R} = \frac{dL}{L} + \frac{d\rho}{\rho} + 2\nu \frac{dL}{L} \quad (2.9)$$

Dividindo a Equação 2.9 por $\varepsilon = dL/L$ tem-se:

$$\left(\frac{dR/R}{\varepsilon}\right) = 2\nu + 1 + \left(\frac{d\rho/\rho}{\varepsilon}\right) \quad (2.10)$$

Esta é a equação fundamental para o estudo dos extensômetros. A alteração na resistência ρ ocorre na proporção da variação do volume do material. Levando isso em consideração tem-se:

$$\frac{d\rho}{\rho} = m \frac{dV}{V} \quad (2.11)$$

Onde m é uma constante do material condutor determinada experimentalmente [25].

Assim,

$$\frac{dV}{V} = \frac{dL}{L} + \frac{dA}{A} = \frac{dL}{L} + \left(-2\nu \frac{dL}{L}\right) = (1 - 2\nu)\varepsilon \quad (2.12)$$

Substituindo a Equação 2.12 na 2.11, e em seguida na 2.10, tem-se:

$$\left(\frac{dR/R}{\varepsilon}\right) = (2\nu + 1) + [m(1 - 2\nu)] = (1 + m) + 2\nu(1 - m) \quad (2.13)$$

A maioria dos materiais resistivos utilizados na construção dos extensômetros são ligas de cobre e níquel, onde o valor de m é igual a uma unidade. Com isso, substituindo m por 1 na Equação 2.13, obtém-se,

$$\frac{dR/R}{\varepsilon} \cong 2. \quad (2.14)$$

Com isso definindo a sensibilidade do material à deformação. A constante K é determinada de acordo com o material utilizado na construção do extensômetro resistivo. Assim, a Equação 2.14 pode ser estabelecida como,

$$\frac{dR}{R} = K\varepsilon. \quad (2.15)$$

O valor da variável (K) varia entre 2,0 e 2,6 para os extensômetros mais comuns. A Tabela 2.1 demonstra os valores da sensibilidade de alguns materiais utilizados na construção de extensômetros.

Tabela 2.1 - Valores da sensibilidade à deformação de alguns materiais [25].

Metal ou Liga	Nome Comercial	Sensibilidade
Advance ou Constantan	45% Ni, 55% Cu	2,1
Nichrome V	80% Ni, 20% Cr	2,2
Isoelastic	36%Ni, 8% Cr, 0,5% Mo, 55,5% Fe	3,6
Karma	74% Ni, 20% Cr, 3% Al, 3% Fe	2,0
Armour D	70% Fe, 20% Cr, 10% Al	2,0
Alloy 479 (Platinum Tugsten)	92% Pt, 8% W	4,1

A deformação ϵ é uma variável adimensional, porém, frequentemente ela é expressa como a razão de duas unidades de comprimento, por exemplo, como m/m [16].

2.1.1.4 Circuito de Medição

Ao utilizar extensômetros para realizar medições de deformação, tem que se considerar que os extensômetros operam com valores muito baixo de tensão, na ordem de microvolts, isso se dá pela baixíssima variação de resistência. Com isso torna-se necessário utilizar um sistema de medição muito preciso. Para medir essas pequenas variações, os extensômetros são quase sempre usados em configurações baseadas em ponte de Wheatstone¹², alimentada com uma fonte de tensão [16].

2.1.1.4.1 Pontes de Wheatstone

A ponte de Wheatstone é um circuito muito utilizado nas aplicações usando

¹² Inventor britânico nascido em 6 de fevereiro de 1802 e morreu em 19 de outubro de 1875.

extensômetros devido a sua alta sensibilidade. É composta por quatro elementos resistivos e pode ser alimentada por uma fonte (tensão ou corrente). Na Figura 2.4 observa-se a configuração da ponte de Wheatstone.




Figura 2.4 - Ponte de Wheatstone [16].

Na Figura 2.4 é possível verificar as variáveis R_1 , R_2 , R_3 e R_4 , que representam as resistências elétricas dos quatro resistores, que podem ser representados por extensômetros. Nesta figura, V_E representa a tensão de excitação, e V_S é a tensão de saída ou sinal de medição.

Para analisar o princípio de funcionamento da ponte, considerando-a como um circuito de medição (onde a tensão de saída determina a deformação do extensômetro) é necessário equacionar o circuito da Figura 2.4.

Os resistores em série dividem a tensão e, assim, a tensão nos resistores em paralelo não varia, com isso, apenas a corrente varia. Considerando uma tensão entre os pontos A e C, a tensão no ponto AB é dada por:

$$V_{AB} = \left(\frac{R_1}{R_1 + R_2} \right) V_E \quad (2.16)$$

De maneira análoga, a tensão em o ponto AD é:

$$V_{AD} = \left(\frac{R_4}{R_4 + R_3} \right) V_E \quad (2.17)$$

Dessa forma pode-se concluir que a tensão de saída V_S é a tensão do ponto BD , assim,

$$V_S = V_{BD} = V_{AB} - V_{AD} \quad (2.18)$$

Substituindo as equações 2.16 e 2.17 na Equação 2.18, tem-se:

$$V_S = V_E \left(\frac{R_1 R_3 - R_2 R_4}{(R_1 + R_2)(R_3 + R_4)} \right) \quad (2.19)$$

A condição de equilíbrio da ponte ocorrerá quando,

$$R_1 R_3 = R_2 R_4 \quad (2.20)$$

Para analisar a condição inicial da ponte é preciso considerá-la balanceada, ou seja, a Equação 2.20 é atendida. Após isso, caso as resistências iniciais R_1 , R_2 , R_3 e R_4 , sofram variações ΔR_1 , ΔR_2 , ΔR_3 e ΔR_4 , respectivamente. A tensão de saída V_S , respeitando a Equação 2.19 será [16]:

$$V_S = V_E \left(\frac{(R_1 + \Delta R_1)(R_3 + \Delta R_3) - (R_2 + \Delta R_2)(R_4 + \Delta R_4)}{(R_1 + \Delta R_1 + R_2 + \Delta R_2)(R_3 + \Delta R_3 + R_4 + \Delta R_4)} \right) \quad (2.21)$$

Assim,

$$V_S = \frac{\left[\left(1+\frac{\Delta R_1}{R_1}\right)\left(1+\frac{\Delta R_3}{R_3}\right)-\left(1+\frac{\Delta R_2}{R_2}\right)\left(1+\frac{\Delta R_4}{R_4}\right)\right]}{\left(1+\frac{\Delta R_1}{R_1}+\frac{R_2}{R_1}+\frac{\Delta R_2}{R_1}\right)\left(1+\frac{\Delta R_3}{R_3}+\frac{R_4}{R_3}+\frac{\Delta R_4}{R_3}\right)} V_E. \quad (2.22)$$

Desprezando os termos de segunda ordem na Equação 2.22 [28], tem-se:

$$V_S = \frac{V_E}{4} \left(\frac{\Delta R_1}{R_1} - \frac{\Delta R_2}{R_2} + \frac{\Delta R_3}{R_3} - \frac{\Delta R_4}{R_4} \right). \quad (2.23)$$

Utilizando a Equação 2.15 e reescrevendo a Equação 2.23 para quatro extensômetros idênticos, tem-se:

$$V_S = \frac{V_E * K}{4} (\epsilon_1 - \epsilon_2 + \epsilon_3 - \epsilon_4) \quad (2.24)$$

A Equação 2.24 mostra que a ponte de Wheatstone é um circuito relacional, no qual a sensibilidade da tensão de saída é proporcional à tensão de alimentação e ao número de extensômetros na ponte [16].

2.1.1.5 Configurações dos Extensômetros

Existem várias configurações que a ponte de Wheatstone pode ser montada como, quarto-de-ponte, meia-ponte, meia-ponte diagonal e ponte completa. Essas configurações dependem do número de extensômetros que serão utilizados.

2.1.1.5.1 Circuito Quarto-de-Ponte

Essa configuração é utilizada quando apenas um extensômetro é usado, ou seja, apenas uma das resistências da ponte de Wheatstone é um extensômetro, as resistências restantes possuem valores fixos. As Figuras 2.5 e 2.6 demonstram a configuração desse

tipo de circuito e como é realizada a montagem do extensômetro, respectivamente.




Figura 2.5 - Circuito quarto-de-ponte [16].



Figura 2.6 - Montagem do extensômetro em quarto-de-ponte [12].

Ao utilizar essa configuração é necessário saber o comportamento do circuito, ou seja, um acréscimo da resistência do extensômetro diminui a tensão de saída, enquanto que um decréscimo faz aumentar o valor da tensão de saída. Desta forma é imprescindível posicionar o extensômetro no sentido correto da medição, pois como visto, a polarização tensão de saída depende dessa posição do extensômetro.

Neste tipo de configuração, as resistências R_2 , R_3 , R_4 e a resistência inicial (nominal) do extensômetro devem ser iguais, ou seja, $R_2 = R_3 = R_4 = R_{nominal}$. A partir da Equação 2.23 é possível deduzir que para uma pequena variação na resistência do extensômetro, a deformação (ε_1) é dada por:

$$\varepsilon_1 = \frac{4 \cdot V_{out}}{V_{exc} \cdot K} \quad (2.25)$$

2.1.1.5.2 Circuito Meia-Ponte

Este tipo de configuração é normalmente utilizado para realizar a compensação de temperatura (ver seção 2.1.1.6.1) no ponto de medida, realizando a compensação da diferença entre os coeficientes de dilatação térmica do extensômetro e da peça instrumentada.




Figura 2.7 - Circuito de meia-ponte [16].

Assim a saída (deformação) para esse circuito é,

$$\varepsilon_1 - \varepsilon_2 = \frac{4 \cdot V_{out}}{V_{exc} \cdot K}. \quad (2.26)$$

Analisando a Equação 2.26 é possível constatar que ao colocar um extensômetro idêntico no mesmo lado da ponte não influenciará o valor de V_{out} . Como a variação da resistência em ramos adjacentes permanecerá, teoricamente a mesma, a relação entre as suas resistências continuará igual e os seus efeitos serão cancelados.

Esta configuração pode reduzir significativamente os erros resultantes em função das variações de temperatura. Para isso, os dois extensômetros devem ser idênticos, bem como devem

estar sujeitos à mesma temperatura. É recomendado que um dos extensômetros fosse montado sobre uma parte não tensionada do material ou orientado adequadamente [16].

2.1.1.5.3 Circuito Meia-Ponte Diagonal

Um dos circuitos mais utilizados é o de quarto-de-ponte, com isso, há uma maneira de se deixar esse circuito mais sensível. Deve se adicionar outro extensômetro no circuito, como mostrado na Figura 2.8, sujeito à mesma deformação, assim a sensibilidade da ponte será duplicada, se transformando no circuito de meia-ponte diagonal.




Figura 2.8 - Circuito meia-ponte diagonal [16].

Assim a deformação é dada por:

$$\varepsilon_1 = \varepsilon_4 = \frac{2 \cdot V_{out}}{V_{exc} \cdot K} \quad (2.27)$$

A Figura 2.9 mostra como deve ser a montagem do circuito de meia-ponte diagonal.



Figura 2.9 - Montagem do extensômetro em meia-ponte [16].

2.1.1.5.4 Ponte Completa

Esse tipo de configuração é para análises mais elaboradas e complexas, pois é preciso utilizar quatro extensômetros. Esses extensômetros devem ter deformações iguais, porém opostas, com isso deixando todos os ramos da ponte ativos, e com isso aumentando a sensibilidade em quatro vezes.




Figura 2.10 - Circuito ponte completa [16].

A deformação é dada por:

$$\varepsilon = \frac{V_{out}}{V_{exc} * K}. \quad (2.28)$$

A Figura 2.11 demonstra uma maneira que esse circuito pode ser utilizado.




Figura 2.11 - Montagem do extensômetro em ponte completa [16].

2.1.1.6 Considerações Sobre os Extensômetros

Ao projetar circuitos utilizando extensômetros algumas considerações devem ser levado em conta como, efeito da temperatura, efeito da resistência dos cabos, sensibilidade transversal, alongamento estático, dissipação de calor e sobre os erros de medição.

2.1.1.6.1 Efeito da Temperatura

O extensômetro é um dispositivo desenvolvido para realizar deformação mecânica, e isso pode acontecer de dois modos:

- Variações na força aplicada ao sensor (desejável);
- Variações de temperatura (não desejável).

A temperatura é um dos fatores geradores de erros nos circuitos que utilizam extensômetros, assim, é muito normal a utilização de extensômetros no mesmo circuito para realizar a compensação desse erro, como relatado na seção 2.1.1.5.2.

2.1.1.6.2 Efeito da Resistência dos Cabos

Todo o equacionamento apresentado para as configurações de extensômetros em quarto-de-ponte, meia-ponte, meia-ponte diagonal e ponte completa foram realizados apresentando a situação ideal de funcionamento da ponte de Wheatstone, ou seja, assumindo que a resistência dos cabos conectados à ponte é desprezível. Porém, na prática, ao se desconsiderar essa resistência do cabo um erro estará sendo inserido na medição, e isso é um grave erro.

Existem algumas soluções par minimizar esses efeitos, por exemplo, no circuito quarto-de-ponte o extensômetro pode ser conectado a dois ou três cabos. A Figura 2.12 demonstra como realizar a ligação a dois cabos. Esse tipo de configuração, dependendo do tamanho do cabo, pode inserir erros nos dados levantados devido a variações na temperatura e reduzir a sensibilidade do circuito.




Figura 2.12 - Montagem do extensômetro a dois cabos em quarto-de-ponte [16].

A configuração que liga a três cabos é mostrada na Figura 2.13, ela reduz a perda de sensibilidade na configuração a dois cabos e proporciona um balanceamento da ponte de Wheatstone intrínseco, e a compensação automática para os efeitos de variações de temperatura no cabeamento, sobre os dados medidos [28].




Figura 2.13 - Montagem do extensômetro a três cabos em quarto-de-ponte [16].

2.1.1.6.3 Sensibilidade Transversal

A resistência elétrica dos extensômetros varia devido à deformação na direção efetiva, na qual é verificada a relação disponibilizada pelo fator de sensibilidade. A direção efetiva tem o mesmo sentido dos filamentos da grade do extensômetro. Assim, quando é aplicada uma deformação transversal na direção efetiva do extensômetro, ocorre uma variação na resistência elétrica.

Com isto, pode afirmar-se que o extensômetro possui sensibilidade transversal. Por norma os fabricantes fornecem o valor do fator de sensibilidade transversal. Estes valores são utilizados em aplicações que exigem uma elevada precisão nas medições práticas [16].

2.1.1.6.4 Alongamento Estático

Essa consideração em específico está relacionada à seção 2.1.1.2, que estabelece a lei de deformação, chamada lei de Hooke. Como qualquer material, os extensômetros também possuem restrições em relação à faixa de medição de deformações, essa faixa

depende do limite elástico do material que é feito o extensômetro. Assim, o extensômetro deve ser compatível com as estruturas e variáveis a serem analisadas.

Além disso, é muito importante o processo de colagem, sendo necessária a utilização de um adesivo que seja estável com a variação de temperatura, para que toda a tensão mecânica seja transmitida para o extensômetro. Paralelamente a isto, o extensômetro deve ser isolado eletricamente da peça em que está aderido e deve estar protegido do ambiente externo [16].

2.1.1.6.5 Dissipação de Calor

Como já foi analisado o efeito da variação de temperatura na medição de deformação, é muito importante estabelecer um valor para a tensão ou para a corrente de excitação dos extensômetros, por causa da dissipação de calor por efeito Joule¹³. A potência dissipada é definida pela Equação 2.29.

$$P = \frac{V^2}{R} = R * I^2. \quad (2.29)$$

2.1.1.6.6 Erros de Medição

Existem várias fontes de erro ao realizar medições com extensômetros em ponte de Wheatstone [16]. São eles:

- Não linearidade da ponte;

¹³ Quando um condutor é aquecido ao ser percorrido por uma corrente elétrica, ocorre a transformação de energia elétrica em energia térmica.

- Erros causados pela precisão e resolução do equipamento de medição;
- Efeitos de temperatura;
- Efeitos da resistência dos cabos;
- Auto-aquecimento dos extensômetros. Este efeito pode ser reduzido, alimentando a ponte, apenas quando se deseja efetuar as medidas.

2.2 Nível de Ruído Teórico

Nesta seção será feito um estudo geral das características que definem os ruídos e serão detalhados alguns tipos diferentes de ruído.

2.2.1 Introdução

Atualmente existem várias definições de ruído. A definição relevante de ruído para esse trabalho é definido como: qualquer flutuação não intencional que aparece no topo dos sinais a serem medidos. Em circuitos eletrônicos existem ruídos de tensão e corrente causados por flutuações térmicas dos componentes [29]. Existem vários tipos de ruídos que interferem nos sinais analisados quando é utilizado equipamento elétrico para realizar o monitoramento [21, 22, 23].

2.2.2 Ruído Shot

Por exemplo, ruído Shot é sempre associado a um fluxo de corrente. Ele aparece sempre que uma carga atravessa uma barreira potencial, como uma junção pn ¹⁴. O cruzamento dessa barreira é um evento puramente aleatório. Dessa forma, a corrente instantânea, i , é composta de um grande número de pulsos de corrente aleatórios e

¹⁴ Estrutura fundamental dos componentes dos componentes eletrônicos comumente denominados semicondutores.

independentes, com valor médio i_D .

O ruído Shot é geralmente especificado em termos do quadrado de sua variação média sobre seu valor médio [30]. Isso é descrito pela Equação 2.30,

$$\overline{i_S^2} = \overline{(i - i_D)^2} = \int 2q_i df, \quad (2.30)$$

onde q é a carga do elétron ($1,602 * 10^{-19}C$) e df é a variação da frequência. Esse tipo de ruído tem uma densidade uniforme de energia.

2.2.3 Ruído Térmico

O ruído térmico é causado pela agitação térmica dos transportadores de carga (elétrons ou buracos) em um condutor. Este ruído está presente em todos os elementos resistivos passivos. Esse tipo de ruído também possui uma densidade uniforme de energia, mas independe do fluxo de corrente [30]. O valor do quadrado da média da fonte de ruído da tensão ou corrente é calculado pela Equação 2.31;

$$\overline{e_T^2} = \int 4KTRdf \text{ or } \overline{i^2} = \int \frac{4KT}{R} df \quad (2.31)$$

onde K é a constante de Boltzmann ($1,38 * 10^{-23}(J/K)$), T é a temperatura absoluta em Kelvin (K), R é a resistência em Ohms do condutor e df é a variação da frequência. Os termos $4KTR$ e $4KT/R$ são densidades de energia de tensão e de corrente, com unidades de V^2/Hz e A^2/Hz .

2.2.4 Análise Teórica do Ruído

Uma vez que as fontes de ruídos têm amplitudes que variam aleatoriamente com o tempo, elas só podem ser especificadas por uma função de probabilidade de densidade. Ruído térmico e ruído Shot possuem funções de probabilidade de densidade Gaussiana. Seja δ o desvio padrão da distribuição gaussiana, então por definição, δ^2 (variância) é a variação do quadrado da média sobre o valor médio. Isso significa que em sinais de ruído com distribuição gaussiana, a variação do quadrado da média sobre o valor médio, i^2 ou e^2 , é a variância δ^2 , e o valor RMS¹⁵ é o desvio padrão δ [30].

Teoricamente, a amplitude do ruído pode ter valores que se aproxima do infinito. No entanto, a probabilidade diminui rapidamente com o aumento da amplitude. Um limite efetivo é $\pm 3\delta$, já que a amplitude do ruído está dentro desse limite 99,7% do tempo. A Figura 2.14 mostra graficamente como a probabilidade da amplitude se relaciona com o valor RMS [30].




Figura 2.14 - Comportamento da função densidade de probabilidade gaussiana com as variáveis: RMS, média e desvio padrão [31].

Para efeito de análise, considera-se duas fontes de ruído combinadas (podem existir inúmeras fontes de ruídos). Cada uma possui um gerador de ruído associado

¹⁵ Ou valor eficaz, é uma medida estatística da magnitude de uma quantidade variável.

como mostrado na Equação 2.32 [30]:

$$\overline{e^2}_1 = \int 4KTR_1 df \quad e \quad \overline{e^2}_2 = \int 4KTR_2 df. \quad (2.32)$$

Para calcular o quadrado da tensão média, $\overline{E^2}_t$, através dessas duas fontes, considera-se $E_t(t) = e_1(t) + e_2(t)$ ser o valor instantâneo [30]. Então,

$$\overline{E_t(t)^2} = \overline{[e_1(t) + e_2(t)]^2} = \overline{e_1(t)^2} + \overline{e_2(t)^2} + \overline{2e_1(t)e_2(t)}. \quad (2.33)$$

Uma vez que a tensão dos ruídos, $e_1(t)$ e $e_2(t)$, nascem de fontes diferentes, elas são independentes, e a média de seu produto é zero [30],

$$\overline{2e_1(t)e_2(t)} = 0. \quad (2.34)$$

Isso resulta em,

$$\overline{E_t^2} = \overline{e_1^2} + \overline{e_2^2}. \quad (2.35)$$

Então, contanto que as fontes de ruído se originem de mecanismos separados e sejam independentes, o que geralmente ocorre, o quadrado do valor médio da soma de fontes de ruídos separadas e independentes é a soma individual dos quadrados dos valores médios [30].

Para que a caracterização do ruído seja precisa necessita-se de várias informações, como a da função densidade de probabilidade do ruído. Porém, nem

sempre é possível conhecer detalhadamente essas informações. O funcionamento do algoritmo proposto está fundamentado na desigualdade de Chebyshev¹⁶ [32].

O desvio padrão δ_x de uma variável aleatória x é uma medida do tamanho de sua função densidade de probabilidade. Quanto maior o δ_x , mais larga é a função densidade de probabilidade. A Figura 2.15 ilustra este efeito para uma função densidade de probabilidade gaussiana [32].




Figura 2.15 - Função densidade de probabilidade gaussiana com desvio padrão $\delta = 1$ e $\delta = 3$ [32].

A desigualdade de Chebyshev é uma prova deste fato. Isso pode ser verificado na Equação 2.36 [32],

$$P[|X - \mu| < K\delta] \geq 1 - \frac{1}{K^2} \leftrightarrow P[\mu - K\delta < X < \mu + K\delta] \geq 1 - \frac{1}{K^2}. \quad (2.36)$$

Com $K = \pm 3\delta$ existe uma probabilidade de mais de 90% que a amplitude do sinal esteja dentro desse intervalo.

O cálculo direto da probabilidade envolvendo a distribuição gaussiana exige recursos do cálculo infinitesimal e, mesmo assim, dada a forma da função densidade, não é um processamento elementar. Por isso, elas foram tabeladas, permitindo-nos obter diretamente o valor da probabilidade desejada [33].

¹⁶ Matemático russo nascido em 16 de maio de 1821 e morto em 8 de dezembro de 1894.

A função densidade gaussiana depende de dois parâmetros, μ e δ (média e desvio padrão respectivamente), de modo que, se as probabilidades fossem tabeladas diretamente a partir dessa função, seriam necessárias tabelas de dupla entrada. Recorre-se, por isso, a uma mudança de variável, transformando a variável aleatória X na variável aleatória Z assim definida [33]:

$$Z = \frac{X - \mu}{\delta}. \quad (2.37)$$

Essa nova variável chama-se variável normal padronizada. Sua média é zero e seu desvio padrão é 1 [33].

A determinação dos parâmetros em relação a ruídos se limita ao cálculo de valores médios através de funções de densidade de probabilidade. A especificação exata do valor pontual de amplitude do ruído não é possível determinar teoricamente. Com isso, as contribuições apresentadas pelo algoritmo proposto se tornam ainda mais claras e determinantes para o estudo. O algoritmo contribuindo consideravelmente para a caracterização dos ruídos em sinais monitorados por equipamento eletrônicos. Isso acontece porque o algoritmo proposto consegue estimar o ruído e separá-lo do sinal monitorado.

O algoritmo proposto considera o ruído presente nesse tipo de sinal monitorado como uma função densidade de probabilidade gaussiana.

2.3 Perfilagem Geofísica

O perfil de um poço é a imagem (descrição), ao longo da profundidade, de

características ou propriedades de uma estratigrafia¹⁷ atravessada pelo poço [34].

O perfil de um poço é o trabalho de executar um registro detalhado das formações geológicas perfuradas por sondas. O perfil pode ter descrições com base em análise visual de amostras retiradas dos poços e realizadas na superfície ou adquiridas por medições de variáveis geofísicas, coletadas por instrumentos, para caracterizar um perfil do poço [35].

Perfilagem de poço é a realização de um perfil em um poço, vertical ou inclinado, com medições de determinados parâmetros. O perfil é traçado a partir de uma sonda que é içada ao longo do poço onde o perfil do parâmetro medido é registrado simultaneamente. Em uma mesma sonda, mais de um parâmetro pode ser medido [34].

A Figura 2.16 mostra os passos de uma perfilagem de poço, começando em (a), a sonda é posicionada no fundo do poço onde é determinada sua profundidade, após o acionamento do guincho a sonda é içada até a superfície (b, c) medindo os parâmetros que o modelo da sonda permite.

¹⁷ É o ramo da geologia que estuda os estratos ou camadas de rochas, buscando determinar os processos e eventos que as formaram.

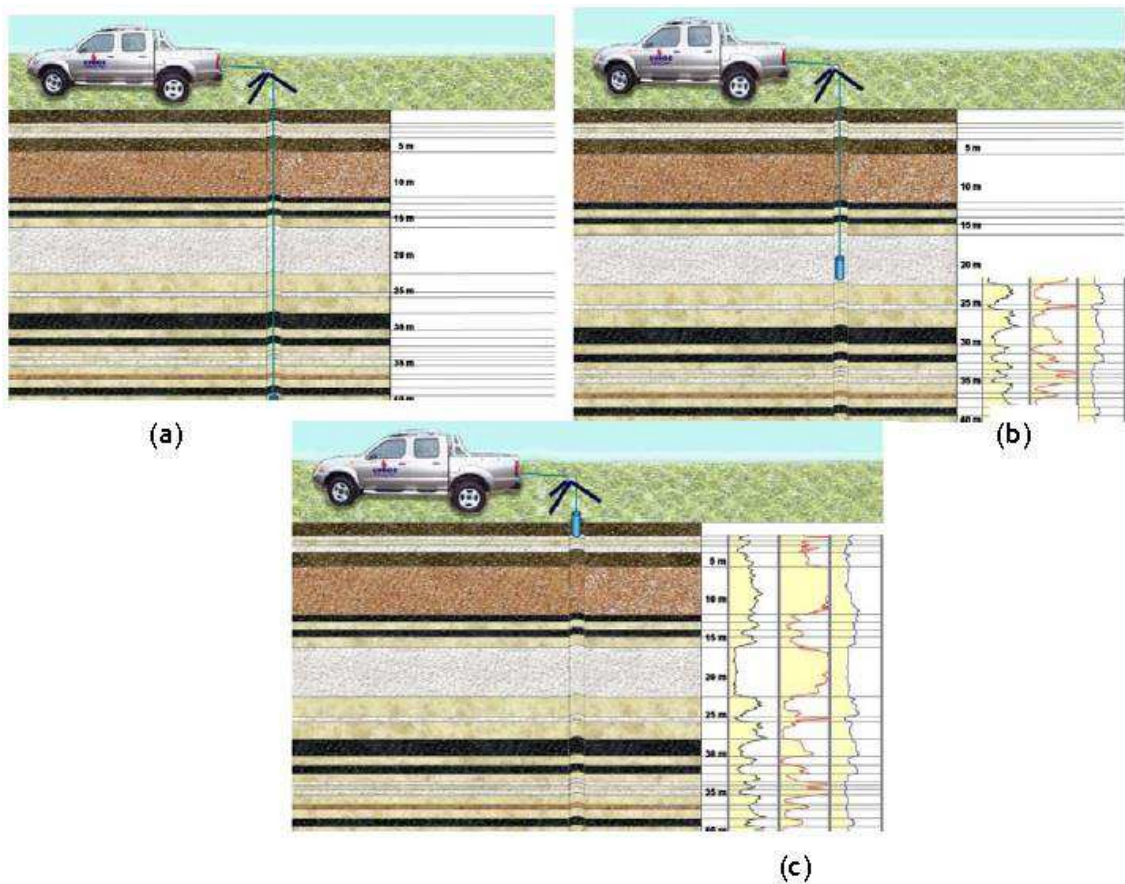


Figura 2.16 - Execução da perfilagem de poço (desenho ilustrativo, sem escala) [34].

A perfilagem de poços é uma ação muito audaciosa e que deve envolver grandes tecnologias. Usam-se equipamentos elaborados e transdutores ligados nas sondas que são levados para o interior do furo em grandes profundidades, podendo atingir até alguns quilômetros. Nessas profundidades, choques mecânicos são frequentes. Temperaturas e pressões começam a se tornar elevadas e suficientes para reduzir a performance dos cabos, conectores e sondas, inserindo níveis de ruído nas leituras obtidas [34].

Existem vários tipos de perfis que podem ser caracterizados, todos com o objetivo de avaliar melhor as formações geológicas, podem ser citados alguns tipos de perfis:

- Raios Gama: detecta a radioatividade total da formação geológica;
- Neutrônico: são utilizados para estimativas de porosidade;
- Indução: Fornece leitura aproximada da resistividade da rocha;
- Sônico: mede a diferença nos tempos de trânsito de uma onda mecânica através das rochas;
- Térmico: mede a variação da temperatura pela variação da profundidade.

2.3.1 Princípio do Método Geotérmico

O campo térmico do subsolo, em profundidades de dezena de metros, sofre influência das variações diurnas e sazonais¹⁸ das temperaturas da superfície. As temperaturas, em profundidades maiores, são menos afetadas pelas variações de curta duração que ocorrem na superfície, e também crescem linearmente com a profundidade devido ao fluxo de calor decorrente do interior da Terra [36].

A taxa de variação da temperatura em função da profundidade é conhecida como gradiente geotérmico, e ele é dependente do fluxo de calor do interior da Terra e das propriedades das formações geológicas locais. Os valores médios de gradientes geotérmicos de algumas localidades são conhecidos, por exemplo, para o Estado de São Paulo que é de 20 a 30°C/km, ou seja, a temperatura aumenta de 2 a 3 °C a cada 100 metros de profundidade [36].

Assim, a presença de água subterrânea através das camadas permeáveis induzem alterações locais na distribuição de temperaturas determinada pelo gradiente geotérmico. Frequentemente, fluxos de águas subterrânea nas formações geológicas permeáveis induzem alterações no campo térmico em escala regional.

¹⁸ Evento que ocorre sempre em uma determinada época do ano ou período constante.

A Figura 2.17 mostra o comportamento das temperaturas resultantes de movimentações ascendentes (linha vermelha), movimento da água de cima para baixo, e descendentes (linha azul), movimento da água de baixo para cima. Assim, a linha verde indica a variação da temperatura na ausência de movimentação de água dentro de um poço. Esta variação linear representa o gradiente térmico esperado na região.




Figura 2.17 - Variação da temperatura com a profundidade, considerando gradiente geotérmico de $25^{\circ}\text{C}/\text{km}$ [36].

2.4 Considerações Finais deste Capítulo

Este capítulo apresentou a fundamentação teórica dos temas predominantes da primeira parte desta tese. Inicialmente, foi introduzido a teoria sobre Extensometria detalhando alguns tipos de circuitos de medição. Em sequência, a teoria de ruído foi detalhada para que logo depois fossem apresentados os conceitos sobre Perfilagem Geofísica que finalizou esse capítulo.

CAPÍTULO 3

ANÁLISE DE COMPONENTES INDEPENDENTES E SEPARAÇÃO CEGA DE FONTES

Este capítulo apresenta a fundamentação teórica dos temas predominantes da primeira parte desta tese. Inicialmente, é introduzido o fundamento de Análise de Componentes Independentes (ICA) e a Análise de Componentes Principais (PCA), realizando uma revisão dos princípios da Análise de Componentes Independentes, como também dos principais algoritmos que usam a ICA como o objetivo de efetuar a Separação Cega de Sinais.

3.1 Análise de Componentes Independentes (ICA)

Um dos mais interessantes e porque não também, um dos principais problemas nas áreas de estatística, análise de dados, processamento de sinais e redes neurais é diagnosticar uma representação adequada para dados multivariáveis¹⁹. Por razões de simplicidade computacional e conceitual, tal representação é realizada através de uma transformação linear. Nesta transformação, cada componente é uma mistura linear das variáveis originais. Aplicam-se métodos conhecidos para encontrar esta transformação como, por exemplo: Análise de Componentes Principais (PCA – *Principal Component Analysis*); Análise de Fator (FA – *Factor Analysis*) [37]; Projeção de Busca (*Projection Pursuit*) [37, 38, 39]; e a pouco mais de uma década e meia, utiliza-se o método de Análise de Componentes Independentes (ICA – *Independent Component Analysis*) [37, 40, 41, 42].

¹⁹ Estudo de três ou mais variáveis simultaneamente.

A principal função da Análise de Componentes Independentes (ICA) é definir uma representação linear de dados não gaussianos, de forma que a dependência estatística entre eles seja minimizada, assim encontrando componentes independentes estatisticamente, ou mais independentes possíveis. A vantagem da ICA é que ela trabalha com componentes não gaussianos e estatisticamente independentes, isso a diferencia das outras técnicas existentes. Esta estrutura é utilizada para diagnosticar os componentes em várias aplicações como separação de sinais [43].

A Análise de Componentes Independentes é uma técnica estatística e computacional que revela componentes ou fatores subjacentes a um conjunto de variáveis aleatórias, medições, ou sinais observados multivariados. Difere das técnicas tradicionais utilizadas nesta área, porque tais componentes são estatisticamente independentes (ou têm dependência estatística minimizada) e são não gaussianos [37].

3.1.1 Histórico da ICA

As pesquisas na área de processamento cego de fontes (BSP – Blind Source Processing) iniciaram-se na metade da década de 80, mais precisamente na França, onde os primeiros trabalhos sobre o tema foram publicados. Um dos primeiros trabalhos publicados na área foi em abril de 1986, no encontro de computação, mais precisamente sobre Redes Neurais realizado em Snowbird (Utah, EUA). Segundo Jeanny Herault e Christian Jutten o artigo intitulado “*Space or Time Adaptive Signal Processing by Neural Network Models*” era capaz de realizar a separação cega de sinais independentes. Este trabalho significou um marco para a área de processamento de sinais [44].

No decorrer dos anos 80, as técnicas para ICA, desenvolvidas inicialmente pelos franceses, não demonstraram influência no cenário internacional. Mas, somente no final dos anos 80 e início dos anos 90 que foram publicados os primeiros artigos relacionados à ICA [41, 42] com relativa importância para o avanço das técnicas de separação cega de fontes utilizando estatísticas de ordem superior. Comon em 1994 coloca novamente os olhares científicos para a separação cega de fonte, provando que o critério de independência estatística entre fontes originais é um argumento suficiente para realizar a separação das fontes sujeitas a misturas lineares [43].

O trabalho de Comon em 1994 consagrou a Análise de Componentes Independentes, mesmo tendo a ICA aplicada a separação cega de fontes algumas limitações, como, a necessidade de conhecer ou estimar a função densidade de probabilidade das fontes originais [41]. Em 1995, Bell e Sejnowski, apresentaram um artigo baseado no princípio de Maximização da Informação associando o Princípio de Separação Cega de Fonte à Teoria da Informação [45].

Em 1996, Bell colaborou à distância com Te - Won Lee em seu trabalho para separação cega de fontes acústicas considerando atrasos de tempo (*Time Delays*) [46].

O algoritmo desenvolvido por Bell e Sejnowski em 1995 foi melhorado por Cardoso e Laheld em 1996, introduzindo uma classe de algoritmos adaptativos que foi denominado EASI²⁰ (Equivariant Adaptative Separation via Independence). Assim, esse algoritmo sendo baseado na idéia de atualização serial da matriz de separação, gerando algoritmos simples. E outro ponto crucial é que o desempenho independe da matriz de mistura, dependendo somente da distribuição normalizada das fontes [43].

Em 1997 pesquisadores da Universidade de Tecnologia Helsinque na Finlândia, desenvolveram um algoritmo de ponto fixo para ICA ou chamado FastICA, que

²⁰ ICAZ2003 [113].

melhorava o desempenho computacional baseado em técnicas simples para determinar a função densidade de probabilidade dos sinais originais [37, 47, 48].

Em 1999, foi desenvolvido um projeto na Europa, não governamental, denominado BLISS (Blind Source Separation and Applications). Como o próprio nome já indica, o projeto era voltado para pesquisa em BSS e ICA com intenção de desenvolver trabalhos utilizando misturas instantâneas e convolutivas, presença de ruído, métodos adaptativos e/ou não lineares. Trabalhos estes aplicados a Telecomunicações e Engenharia Biomédica [9].

Em 2003, foi realizada a Conferência Internacional sobre Análise de Componentes Independentes e Separação Cega em Nara, Japão, assim atraindo pesquisadores de diferentes áreas, entre elas, destacam-se as áreas de engenharia biomédica, processamento de voz e comunicações móveis. Com isso, foram apresentadas várias aplicações e inúmeros novos algoritmos ou versões modificadas dos algoritmos existentes [9].

Deste modo, a ICA vem ganhando força considerável no cenário de pesquisas internacionais. Por esse motivo, nesse trabalho, será utilizada essa técnica como suporte para analisar sinais de sensores, especificamente em sinais de extensometria.

3.1.2 Condições de Contorno da ICA

Seja o vetor aleatório $X = [X_1, X_2, \dots, X_n]^T$, cujos n elementos são gerados pela mistura de n componentes independentes entre si de um vetor aleatório $S = [S_1, S_2, \dots, S_n]^T$. O modelo ICA expressa cada X_i como uma combinação linear de componentes independentes, dado por:

$$X_i = a_{i1}S_1 + a_{i2}S_2 + \dots + a_{in}S_n, \quad (3.1)$$

para todo $i = 1, 2, \dots, n$, em que a_{ij} , $j = 1, 2, \dots, n$, são coeficientes reais.

Usando notação matricial o modelo pode ser escrito como,

$$X = A . S, \quad (3.2)$$

em que A é a matriz dos coeficientes a_{ij} das combinações lineares.

Sendo a_{ij} um coeficiente que proporciona a mistura dos componentes independentes (sinais ou fontes originais), a matriz A é conhecida como matriz de mistura. Tanto os coeficientes a_{ij} assim, como os coeficientes independentes S_i não são conhecidos e devem ser estimados através dos sinais misturados X_i .

Alternativamente pode-se definir ICA como o problema de determinar uma transformação linear dada pela matriz W ,

$$Y = W . X, \quad (3.3)$$

onde Y é um vetor aleatório de componentes Y_1, Y_2, \dots, Y_n que são estimativas dos componentes independentes e W é a matriz inversa de A , nomeada de matriz separação.

Através da Equação 3.3 pode-se verificar o objetivo do método que realmente é estimar os componentes independentes [49]. Na Figura 3.1 é demonstrado o processo de estimação a partir da Análise de Componentes Independentes.

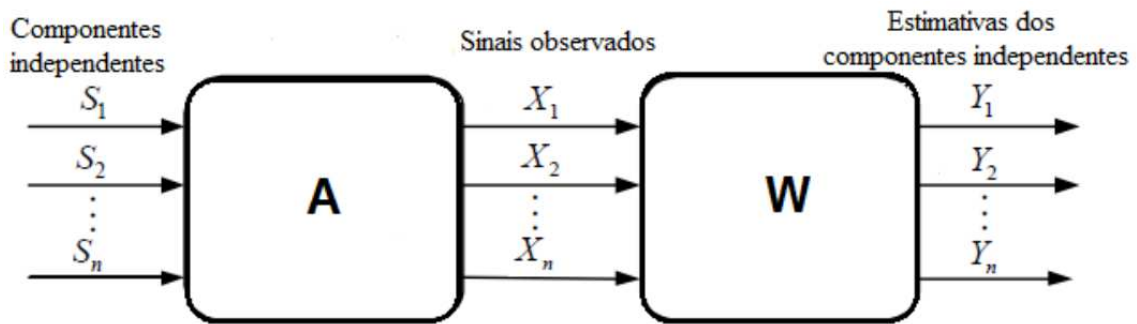


Figura 3.1 - Modelo de mistura e separação da Análise de Componentes Independentes.

Esta estrutura do modelo de mistura e separação da Análise de Componentes Independentes é uma das mais simples, pois não se aplica a somatória de ruído aos sinais observados X_i e considera a mistura linear [37]. A configuração de análise completa, ou seja, considerando ruídos, será estudada quando for apresentado o conceito de BSS (*Blind Source Separation*) mais a frente.

3.1.3 Premissas do Modelo

Para que o modelo ICA esteja bem delimitado e caracterizado é necessário realizar algumas suposições, já citadas anteriormente, como, os componentes S_i (coeficientes independentes) sejam estatisticamente independentes entre si, e que apresentem uma distribuição de probabilidade não gaussiana.

3.1.3.1 Independência Estatística

Duas variáveis aleatórias Y_i e Y_j são consideradas independentes se o conteúdo da informação na variável Y_i não indica nenhuma informação sobre a probabilidade de ocorrência da variável Y_j , para $i \neq j$.

Encontram-se as definições e condições exigidas pelo modelo ICA para

determinação de independência estatística em [44].

Considere Y_1, Y_2, \dots, Y_n variáveis aleatórias (v.a.) possuindo função densidade conjunta $f(y_1, y_2, \dots, y_n)$. Assim, através do conceito que diz que as variáveis Y_i são estatisticamente independentes se a função densidade conjunta pode ser definida como:

$$f(y_1, y_2, \dots, y_n) = f_1(y_1)f_2(y_2) \dots f_n(y_n), \quad (3.4)$$

em que $f_i(y_i)$ representa a densidade marginal de Y_i , para todo $i = 1, 2, \dots, n$.

Através do conceito de esperança é possível demonstrar que,

$$E[g(Y_i)h(Y_j)] = E[g(Y_i)].E[h(Y_j)], \text{ para } i \neq j, \quad (3.5)$$

em que $g(Y_i)$ e $h(Y_j)$ são quaisquer funções integráveis de Y_i e Y_j .

Mas, por outro lado, é considerado duas variáveis Y_i e Y_j não correlacionadas quando a covariância entre elas é nula,

$$Cov(Y_i, Y_j) = E(Y_i Y_j) - E(Y_i) * E(Y_j) = 0, \quad (3.6)$$

o que correlaciona a,

$$E(Y_i Y_j) = E(Y_i) * E(Y_j), \text{ para } i \neq j. \quad (3.7)$$

Como se trabalha mais com variáveis aleatórias de média nula, então tem-se que:

$$E(Y_i Y_j) = 0 \quad (3.8)$$

mas isso também é uma condição de ortogonalidade.

Analisando as Equações 3.5 e 3.7 é possível concluir que independência estatística é uma propriedade muito mais relevante do que a não correlação. Consequentemente, a Equação 3.7 que estabelece a não correlação pode ser entendida como um caso específico da propriedade de independência (Equação 3.5), onde $g(Y_i)$ e $h(Y_j)$ são funções lineares [49].

3.1.3.2 Variáveis Não Gaussianas

Como já foi dito anteriormente, a restrição de variáveis não gaussianas para componentes independentes é uma condição fundamental no modelo ICA, como será demonstrado a seguir. Se as fontes forem gaussianas não há como separá-las através de métodos que utilizem somente a independência estatística das fontes.

Considerando que S_1 e S_2 sejam dois componentes independentes gaussianos normalizados²¹ e descorrelacionados, pode se dizer que a função densidade de probabilidade conjunta é dada por:

$$f(s_1, s_2) = \frac{1}{2\pi} e^{\left(-\frac{s_1^2 + s_2^2}{2}\right)} = \frac{1}{2\pi} e^{\left(-\frac{\|s\|^2}{2}\right)}. \quad (3.9)$$

Assumindo que a matriz A seja ortogonal, tem-se que $A^{-1} = A^T$. Fazendo o uso da fórmula clássica do método jacobiano para transformações de funções de densidade de probabilidade obtém-se que a densidade conjunta das misturas X_1 e X_2 , obtidas pela transformação (Equação 3.2), é dada por:

²¹ Média nula e variância unitária.

$$f(x_1, x_2) = \frac{1}{2\pi} e^{\left(-\frac{\|A^T \cdot x\|^2}{2} |\det A^T| \right)} \quad (3.10)$$


Se A é ortogonal, assim A^T também é ortogonal e segue-se que $\|A^T \cdot x\|^2 = \|x\|^2$ e $|\det A| = 1$.

Assim,

$$f(x_1, x_2) = \frac{1}{2\pi} e^{\left(-\frac{\|x\|^2}{2} \right)}, \quad (3.11)$$

com isso pode-se concluir que uma matriz de mistura ortogonal não altera a função densidade de probabilidade (f.d.p.) conjunta de misturas gaussianas, pois sequer é relacionada na f.d.p. da mistura.

Analisando a Figura 3.2 que representa a distribuição conjunta de duas fontes gaussianas e fontes de distribuição uniforme. É possível verificar na Figura 3.2(a) que a densidade é extremamente simétrica e não é modificada ao ser submetida a uma rotação. A f.d.p. e a sua representação gráfica não contempla nenhuma informação sobre as orientações das colunas da matriz de mistura. Já na Figura 3.2(b) verifica-se a existência de direções preferenciais quando as fontes são de distribuição uniforme [50].



(a): Mistura de fontes gaussianas.

(b): Mistura de fontes uniformes.

Figura 3.2 - Funções de distribuição de probabilidade conjuntas de variáveis gaussianas e uniformes em um sistema de mistura instantânea [50].

As propriedades de não correlação e independência são equivalentes nas variáveis gaussianas, onde são definidas por suas médias e covariâncias. Tendo o entendimento destas restrições das variáveis gaussianas, e apesar delas, é imprescindível verificar que o modelo ICA não requer qualquer prévio conhecimento sobre as distribuições de probabilidades dos componentes independentes [49].

No caso de variáveis não gaussianas, entretanto, a independência garante que as fontes são realmente distintas e é neste critério que são baseados a maioria dos métodos de separação cega de fontes [50].

3.1.4 Ambiguidades da ICA

Inerentes ao modelo de separação cega existem algumas ambiguidades ou indeterminações, que são condicionadas pelo modelo geral ICA. Assim, as principais ambiguidades e indeterminações são:

- a) Não é possível estimar a variância (energia) dos componentes independentes.

Decorrencia deste fato, não é possível estabelecer a amplitude dos componentes independentes. Considerando que são variáveis aleatórias, o jeito mais simples de solucionar esse evento é considerar que cada componente tem variância unitária, ou seja, $E(S_i^2) = 1$, já que tanto os sinais originais S_i como a matriz de mistura A não são conhecidas. A técnica de considerar a variância unitária é devido ao fato que qualquer valor constante α_i multiplicados aos sinais originais S_i pode ser anulado quando dividido pelo mesmo coeficiente α_i na coluna correspondente de a_i da matriz de mistura A .

$$X = \sum_{i=1}^n \left(\frac{1}{\alpha_i} a_i \right) (S_i \alpha_i). \quad (3.12)$$

Ainda dentro desse campo, é possível verificar a ambiguidade em relação ao sinal (negativo ou positivo) dos sinais estimados. Esta questão pode ser desfeita multiplicando-se os componentes independentes estimados por -1, sem fugir do modelo original.

- b) Não é possível determinar a ordem dos componentes independentes. A razão está no fundamento do modelo, de tanto os sinais originais S_i como a matriz de mistura A não são conhecidos, assim, é possível realizar a troca da ordem dos elementos destas matrizes. Isso pode ser representado da seguinte maneira, utilizando uma matriz de permutação P e de sua inversa P^{-1} , que serão substituídas na Equação 3.2, onde os elementos de PS são componentes independentes em outra ordem, e AP^{-1} é outra matriz de

mistura a ser estimada.

$$X = AP^{-1}PS \quad (3.13)$$

3.1.5 Técnicas de Pré – Processamento

A maioria dos métodos baseados na teoria da ICA necessitam que os dados sejam pré-processados. As técnicas de pré-processamento são aplicadas no conjunto de misturas. Essa etapa de pré-processamento pode tornar a questão da estimativa do modelo ICA consideravelmente simplificada. Com objetivo de facilitar a análise, como também o desenvolvimento teórico, além de diminuir a complexidade computacional dos algoritmos [51].

Existem várias técnicas utilizadas na fase de pré-processamento, mas os métodos mais utilizados nessa fase pelas técnicas de Análise de Componentes Individuais (ICA) são a Centralização (*Centering*) e o branqueamento (*Whitening*) [37, 38].

3.1.5.1 Centralização

Esta técnica de pré-processamento é um procedimento básico e necessário para o modelo ICA. Ela baseia-se em realizar a subtração da média dos dados observados, com isso, tornando a média dos dados nula [49]. O processamento inicial é feito através da centralização dos dados de X . Essa etapa é realizada subtraindo a média $E[x(k)]$ de cada elemento de $x(k)$, tornando $x(k)$ uma variável de média nula. Assim, implica que $s(k)$, valores estimados, também tenham média nula [37].

Considere \bar{X} o vetor aleatório das variáveis observadas. O vetor submetido ao algoritmo ICA será:

$$X = \bar{X} - E(\bar{X}). \quad (3.14)$$

Como já foi dito, a média dos componentes independentes estimados também será nula, de acordo com a Equação 3.15,

$$E(Y) = W \cdot E(X). \quad (3.15)$$

Ao realizar este procedimento, não afeta a estimação da matriz de mistura que continua a mesma independentemente da média dos dados observados e dos componentes independentes.

Ao estimar os componentes independentes dos dados originais, esses deverão ter a média repostada como segue,

$$\bar{Y} = Y + W \cdot E(\bar{X}). \quad (3.16)$$

Sendo a distribuição de probabilidade do vetor aleatório geralmente não conhecida, na prática a esperança é computada pela média amostral das realizações dos vetores aleatórios [49].

3.1.5.2 Branqueamento

As informações estatísticas de segunda ordem não permitem a separação em componentes independentes. Mas, analisando de outro lado, a descorrelação espacial ou independência de segunda ordem permite expressar o espaço dos sinais medidos em um sistema ortogonal, ou branco, que ainda não implica na independência estatística destas

medidas, mas ajuda a simplificar muito o algoritmo [42].

O processo de branqueamento baseia-se em tornar as variáveis observadas não correlacionadas e com variância unitária, ou seja, a matriz de covariância dos dados branqueados é a matriz identidade,

$$\text{cov}(y) = E\{yy^T\} = I. \quad (3.17)$$

Nessa fase do pré-processamento, também denominado esferamento, o vetor de observações X é linearmente transformado em um novo vetor Z . O Processo é aplicado ao vetor X dos dados originais previamente centralizados.

O vetor de dados branqueados Z é obtido através de uma decomposição ortogonal do vetor de X ,

$$Z = V.X, \quad (3.18)$$

em que,

$$V = ED^{-\frac{1}{2}}E^T, \quad (3.19)$$

sendo E e D , respectivamente, a matriz ortogonal dos autovetores e a matriz diagonal dos autovalores da matriz de covariância amostral de X [49].

Ainda observando que o modelo ICA aplicado aos dados branqueados é bem mais simples, como reguem as Equações 3.2 e 3.18, assim,

$$Z = V.A.S, \quad (3.20)$$

$$Z = \bar{A} \cdot S. \quad (3.21)$$

Assim, a otimização e busca pelos componentes independentes passa a ser feita através do novo vetor Z . De acordo com a Equação 3.21 a nova matriz de mistura \bar{A} é uma matriz ortogonal, com isso, reduzindo a quantidade de parâmetros a serem estimados de n^2 para $\frac{n(n-1)}{2}$. Assim a técnica de branqueamento resolve metade do problema da Análise de Componentes Independentes (ICA) [47], e esta técnica apresenta outro benefício além de diminuir a quantidade de trabalho, ela também melhora o desempenho dos algoritmos da ICA.

Outro benefício do branqueamento, ao realizar a descorrelação dos dados é reduzir a dimensão do problema, como é realizado quando aplica-se a técnica de Análise de Componentes Principais (PCA).

3.1.6 Princípios para Estimativa de Componentes Individuais

A estimativa de dados independentes é feita, frequentemente, utilizando uma função custo, realizando a maximização ou minimização dessa função [41]. O termo função custo é a definição de qualquer função cuja otimização permite a estimativa de componentes independentes.

A diferença entre a função custo e o algoritmo para implementar a ICA é estabelecida em [52], a relação entre eles é mostrada na Figura 3.3.




Figura 3.3 - Relação entre algoritmo, função custo e modelo para ICA.

Como pode-se analisar, o modelo para ICA depende de ambos, tanto do algoritmo de otimização quanto da função custo. As propriedades estatísticas, como consistência e robustez do modelo ICA dependem da escolha da função custo e as propriedades computacionais, como memória, estabilidade e velocidade de convergência dependem da escolha do algoritmo de otimização. Assim, os algoritmos e as funções de custo são totalmente independentes.

Para estabelecer a estimativa dos componentes independentes são utilizadas algumas funções custo, principalmente por meio da maximização da não-gaussianidade, minimização da informação mútua e estimativa da máxima verossimilhança. Embora apresente conceitos diferentes, pode-se demonstrar que matematicamente estas funções são equivalentes [53].

Baseado nestas funções custo uma grande quantidade de algoritmos foram desenvolvidos [9, 41, 45, 48, 54, 55, 56, 57].

3.1.6.1 Maximização da Não Gaussianidade

Uma das maneiras mais comuns de se estimar os componentes independentes é através da não gaussianidade dos componentes, e como já citado anteriormente, após

passar pelo pré – processamento: centralização (média nula) e de branqueamento (variância unitária).

A estimativa por não gaussianidade pode ser realizada por meio do *Kurtosis* ou achatamento da curva da distribuição de probabilidade dos componentes ou também utilizando o princípio da negentropia [37].

3.1.6.1.1 Medida de Não Gaussianidade por Kurtosis

As funções custo mais simples para o modelo ICA são expressas através de cumulantes quarta ordem, ou *Kurtosis*. O *Kurtosis* de uma variável aleatória $y(k)$ é definido como sendo [58, 59],

$$Kurt(y(k)) = E[y(k)^4] - 3(E[y(k)^2])^2. \quad (3.22)$$

Considerando que $y(k)$ tem variância unitária na Equação 3.22 pode-se escrever,

$$Kurt(y(k)) = E[y(k)^4] - 3. \quad (3.23)$$

A Equação 3.23 mostra que o *Kurtosis* é simplesmente uma normalização do momento de quarta ordem.

A função *Kurtosis* possui uma propriedade muito significativa, onde se justifica a sua utilização no modelo ICA. Para uma variável gaussiana, o momento de quarta ordem é dado por $3E[s^2(k)]^2$, como a variância $E[s^2(k)] = 1$; como consequência, o *Kurtosis* é nulo, o que reforça a idéia já dita anteriormente que variáveis gaussianas não

são admitidas para o modelo ICA.

O valor de uma função de *Kurtosis* de uma variável aleatória pode ser positiva, negativa ou nula, como mostra a Tabela 3.1.

Tabela 3.1 - Relação de valores de Kurtosis.

<i>Kurtosis</i>	Tipo da Variável	Tipo da f.d.p.
$Kurt > 0$	Variável Super-Gaussiana ²²	f.d.p. Plana, Uniforme.
$Kurt < 0$	Variável Sub-Gaussiana	f.d.p. Laplaciana.
$Kurt = 0$	Variável Gaussiana	f.d.p. Gaussiana ou Normal

A não gaussianidade pode ser determinada através do valor absoluto do *Kurtosis* ou $(Kurtosis)^2$, sendo assim,

Tabela 3.2 - Kurtosis x Tipo de variável Gaussiana.

$ Kurt = 0$	Variáveis Gaussianas
$ Kurt > 0$	Variáveis Não Gaussianas

Apenas em alguns casos especiais podem-se encontrar variáveis não gaussianas com $|Kurt| = 0$ [58].

²² A notação aqui descrita é mais usada na literatura de engenharia. Na literatura de estatística é comum encontrar-se as expressões *mesokurtica*, *platykurtica* e *leptokurtica* para descrever distribuições gaussiana, sub-gaussiana e super-gaussiana, respectivamente.

As distribuições gaussiana, sub-gaussiana e super-gaussiana podem ser obtidas através da distribuição gaussiana generalizada para variáveis de média nula [38, 60]:

$$p_x(x) = \frac{r}{2\vartheta_x^r \varphi\left(\frac{1}{r}\right)} e^{\left(-\frac{1}{r} \left|\frac{x}{\vartheta_x}\right|^r\right)}, \quad (3.24)$$

em que r é um parâmetro variável que determina o tipo da distribuição (normal, super-gaussiana e sub-gaussiana), $\varphi(r) = \int_0^\infty x^{r-1} e^{-x} dx$ é a função Gamma e $\vartheta_x^r = E\{|x|^r\}$ é a medida generalizada da variância conhecida como dispersão da distribuição [38].

A Figura 3.4 ilustra as distribuições obtidas através da distribuição gaussiana generalizada.




Figura 3.4 - Exemplos da f.d.p. gaussiana, sub-gaussiana e super-gaussiana [61].

Como já comentado anteriormente, os componentes independentes são estimados maximizando ou minimizando o *Kurtosis*, de acordo com o algoritmo

escolhido.

Na prática, para se determinar a matriz de separação W que estimará os componentes independentes $y(k)$ com base na medida dos *Kurtosis* das fontes, seguindo os passos descritos abaixo [47]:

- Aplicar a técnica de pré-processamento chamada centralização, tornando as variáveis com média nula;
- Aplicar a técnica do pré-processamento chamada branqueamento, torna as variáveis não correlacionadas e com variância unitária;
- Inicializar a matriz de separação W com um valor qualquer;
- Determinar a direção em que *Kurtosis* de $y(k)$ está crescendo, ou decrescendo, mais fortemente;
- Baseado nas medidas disponíveis $x(k)$, utilizar um método de gradiente, ou equivalente, para determinar um novo vetor W .

As etapas do processo descrito acima continuam até que todos os componentes de todas as fontes sejam estimados.

A kurtosis ainda possui algumas propriedades importantes, utilizadas na concepção de um critério para separação de fontes. Dentre elas, para variáveis aleatórias y_1 e y_2 , tem-se [37, 47]:

$$Kurt\{y_1 + y_2\} = Kurt\{y_1\} + Kurt\{y_2\} \quad (3.25a)$$

$$Kurt\{\alpha * y\} = \alpha^4 * Kurt\{y\} \quad (3.25b)$$

em que α é um escalar.

As propriedades descritas pela Equação 3.25 são, basicamente, aquelas que devem ser calculadas na saída do filtro (matriz) de separação, uma vez que os sinais processados são, na maioria dos casos estudados, composições lineares de outras fontes [61].

Na linha de buscar respostas à questão analisada no início dessa seção, o interesse aqui é determinar um algoritmo que maximize a Kurtosis de modo que a gaussianidade dos sinais à saída seja minimizada.

Aplicados ao método da ICA existem vários algoritmos que utilizam o *Kurtosis*, mas na prática, esses algoritmos apresentam algumas desvantagens, pois sua implementação computacional é mais complexa, não é uma forma robusta de se estimar a não gaussianidade, e além disso, é sensível a *outliers*²³ (amostras inconsistentes que não se adaptam a curva). Além disso, como o *Kurtosis* é estimado a partir de dados observados, ou amostrados, os valores podem variar bastante em função do número de amostras e alterar a estimativa das fontes [9].

3.1.6.1.2 Entropia e Informação Mútua

Sabe-se que a entropia de uma variável aleatória fornece uma medida da quantidade média de incerteza contida na v.a. (variável aleatória), pode-se definir, para um vetor de v.a. contínuas²⁴ x , sua entropia $\Phi(x)$ é dado por [62]:

$$\Phi(x) = -E\{\ln[p_x(x)]\} = -\int_{-\infty}^{\infty} p_x(x) * \ln[p_x(x)]dx \quad (3.26)$$

²³ Valor atípico: é uma observação que apresenta um grande afastamento das demais da série.

²⁴ Para o caso de valores discretos, tem-se a seguinte forma:

$$\Phi(x) = -E\{\ln[p_x(x)]\} = -\sum_i p_i * \ln[p_i],$$

em que p_i é a probabilidade do evento i .

Na verdade, a Equação 3.26 determina a entropia diferencial de x , uma vez que a incerteza contida numa v.a. contínua é infinita.

Consideremos agora outro vetor de v.a. y , e $p_{x/y}(x/y)$ e f.d.p. de x condicionada a y . Uma medida da incerteza remanescente em x após a observação de y é dada pela entropia condicional, dada por:

$$\Phi(x/y) = -E\{\ln[p_{x/y}(x/y)]\} = -\int p_{x,y}(x,y) * \ln[p_{x/y}(x/y)] dx dy, \quad (3.27)$$

em que,

$$p_{x,y}(x,y) = p_{x/y}(x/y)p_y(y), \quad (3.28)$$

é a f.d.p. conjunta de x e y .

Assim, a conhecida relação [63, 64],

$$I(x,y) = \Phi(x) - \Phi(x/y), \quad (3.29)$$

representa a informação mútua contida em x após a observação de y . Esta grandeza é conhecida como informação mútua entre x e y .

A informação mútua será de grande importância porque ela é sempre não negativa e assume o valor zero se e somente se x e y são independentes. De fato, isso é esperado já que, para variáveis independentes, a observação de uma delas não

fornece nenhuma informação sobre a outra. Isto é fácil de verificar através da Equação 3.29 que, para $I(x, y) = 0$, tem-se $\Phi(x) = \Phi(x/y)$. Logo, a informação mútua apresenta-se como uma referência confiável para independência estatística [50].

3.1.6.1.3 Divergência de Kullback-Leibler

Um problema muito comum detectado em inferência estatística é a definição da medida de similaridade entre funções. A divergência de Kullback-Leibler (KLD – *Kullback-Leibler Divergence*) é uma medida de similaridade entre duas funções estritamente positivas [65], e que proporciona uma medida da divergência entre duas funções de densidade de probabilidade (f.d.p.) $f_y(y)$ e $g_y(y)$, conhecida também como entropia cruzada [66]. A KLD é definida matematicamente como:

$$KLD(f_y(y) \| g_y(y)) = \int_{-\infty}^{\infty} f_y(y) \log \left(\frac{f_y(y)}{g_y(y)} \right) dy, \quad (3.30)$$

em que $f_y(\cdot)$ e $g_y(\cdot)$ são duas funções estritamente positivas. Para o caso discreto tem-se:

$$KLD(f_y(y) \| g_y(y)) = \sum_{y \in \mathcal{E}} f_y(y) \log \left(\frac{f_y(y)}{g_y(y)} \right) dy \quad (3.31)$$

em que \mathcal{E} é o conjunto domínio da variável y .

É muito comum a utilização da KLD para realizar a comparação entre duas funções de densidade de probabilidade. Neste caso, a f.d.p. $g_y(y)$ realiza o papel de uma função de referência.

Deve-se observar que $KLD(f_y(y)||g_y(y)) \neq KLD(g_y(y)||f_y(y))$; significando que $KLD(\bullet//\circ)$ não é uma medida de distância²⁵, embora seja comum na literatura ser referenciada como distância de Kullback-Leibler.

Para justificar o uso de KLD aplicada ao método de ICA existem algumas propriedades importantes [64]:

1. É sempre de valor positivo ou zero; KLD é zero para os casos específicos de $f_y(y) = g_y(y)$.
2. É invariante com relação às seguintes mudanças nos componentes do vetor y :
 - Permutação de ordem;
 - Escalonamento de amplitude.

Ao usar duas funções estritamente positivas, confirma-se ainda a propriedade da KLD de possuir apenas valores positivos e zero.

A propriedade (1) é de extremo interesse para a determinação de funções de otimização, pois proporciona a construção de uma classe de funcionais que têm como referência a teoria da informação, pois utiliza o princípio de mínima entropia através da comparação entre funções [61, 67].

Utilizando o espaço das f.d.p.'s como espaço da métrica das mesmas, pode-se escrever, através do uso da KLD, a seguinte relação entre três f.d.p.'s distintas, $p_a(a)$, $\widetilde{p}_a(a)$ e $p_y(y)$ [64]:

$$KLD(p_y(y)//p_a(a)) = KLD(p_y(y)//\widetilde{p}_a(a)) + KLD(\widetilde{p}_a(a)//p_a(a)). \quad (3.32)$$

²⁵ Não é uma medida de distância no espaço euclidiano, mas pode apresentar no contexto de geometria diferencial como uma métrica de Riemman no espaço das distribuições de probabilidade.

Para equação acima ter validade, algumas condições devem ser respeitadas, que são facilmente atendidas em problema de BSS:

- $y = Ba$, em que y e a são vetores e B é uma matriz não diagonal.
- $\widetilde{p}_a(a)$ é a f.d.p. marginal de cada elemento a_i do vetor a , obtida a partir de $p_a(a)$.

A relação observada na Equação 3.32 é também conhecida por decomposição de Pitágoras por poder ser entendida como uma extensão, para o espaço das f.d.p.'s, do teorema de Pitágoras para triângulos retângulos no espaço Euclidiano [64, 68].

Utilizando a KLD, pode-se ainda determinar a informação mútua como:

$$I(x, y) = \int p_{x,y}(x, y) * \ln \left[\frac{p_{x,y}(x, y)}{p_x(x)p_y(y)} \right] dx dy$$

$$I(x, y) = KLD(p_{x,y}(x, y) // p_x(x)p_y(y)), \quad (3.33)$$

o que sugere que a informação mútua é uma medida da dependência estatística. Assim, é possível ainda afirmar de maneira mais elegante que a informação mútua entre os componentes de um vetor K-dimensional (qualquer dimensão) y como sendo a KLD entre $p_y(y)$ e $\widetilde{p}_y(y)$ dada por [68]:

$$I(y) = KLD(p_y(y) // \widetilde{p}_y(y))$$

$$I(y) = \int \int \dots \int p_y(y_1, y_2, \dots, y_k) * \ln \left[\frac{p_y(y_1, y_2, \dots, y_k)}{\prod_{i=1}^K p_{y_i}(y_i)} \right] dy_1 dy_2 \dots dy_k, \quad (3.34)$$

que assume valor igual à zero se e somente se todos os componentes de y são mutuamente independentes.

Considerando a Equação 3.34, pode-se ainda reescrever [64]:

$$I(y) = -\Phi(y) + \sum_{i=1}^K \Phi(y_i), \quad (3.35)$$

o que significa que minimizar a informação mútua entre os componentes do vetor y representa tornar a entropia de y o mais próxima possível da soma de suas entropias marginais.

3.1.6.1.4 Negentropia

Outra maneira de se determinar a não gaussianidade de uma função é aplicando a negentropia baseada na medida de entropia diferencial [41, 47, 69].

A entropia de uma variável aleatória é o grau de desordem ou desorientação deste sistema; com isso, quanto maior a imprevisibilidade e a desestruturação da variável, maior será sua entropia. Para a mesma variância, as variáveis gaussianas apresentam a maior entropia [58]. Assim, as variáveis gaussianas apresenta uma distribuição mais aleatória ou menos estruturada de todas as distribuições e, a partir disso, a medida de entropia pode ser utilizada como medida de não gaussianidade.

Matematicamente, a negentropia é a diferença entre a entropia da v.a. multidimensional²⁶ y e a entropia de uma v.a. y^G de distribuição gaussiana e com os mesmos momentos de ordem um e dois (média e variância) de y . Assim, tem-se que $p_y^G(y) = N(\mu_y, \sigma_y^2)$, em que μ_y e σ_y^2 são respectivamente a média e a variância da

²⁶ A negentropia pode, logicamente, ser expressa para variáveis unidimensionais.

variável y , sendo sua negentropia dada por [50]:

$$N_G(y) = \Phi(y^G) - \Phi(y). \quad (3.36)$$

Assim, a negentropia é uma grandeza não negativa porque uma variável gaussiana possui sempre uma entropia maior [59].

Escrevendo a Equação 3.36 utilizando a divergência de Kullback-Leibler, a definição de negentropia também pode ser dada por:

$$N_G(y) = KLD(p_y(y) // p_y^G(y)). \quad (3.37)$$

O uso desse parâmetro torna o processamento da BSS mais robusto, uma vez que a medida de negentropia é o estimador muito bom da não gaussianidade [47]. E também, o desenvolvimento de uma função que maximize a negentropia e, por consequência, deixe as fontes estimadas na saída do sistema de separação o menos gaussianas possível, é de fácil dedução [37].

Entretanto, a desvantagem de tal método reside no fato de que a maximização de um funcional que leva em conta a negentropia pressupõe o conhecimento ou a estimativa da função de densidade de probabilidade das fontes na saída do sistema de separação. Como geralmente não se dispõe do conhecimento a priori das fontes, esta estimativa possivelmente deve ser realizada de forma não paramétrica. Este fato limita bastante a utilização da negentropia como critério de otimização para

separação autodidata de fontes, motivando o uso de critérios sub-ótimos de medida de não gaussianidade ou de aproximações no cálculo de negentropia [50].

A partir da análise da Equação 3.36 determina-se,

Tabela 3.3 - Determinação das variáveis através da negentropia.

$N_G(y) = 0$	Variável Gaussiana
$N_G(y) > 0$	Variável Não Gaussiana

Ao utilizar a negentropia como medida de não gaussianidade existe uma vantagem, sua base teórica e matemática bem definida. Outra característica muito importante da negentropia é que ela é invariante para transformações lineares invertíveis [41].

A desvantagem de se utilizar a negentropia como função custo, é que ela necessita de um grande esforço computacional, pois ela necessita de uma estimativa da f.d.p. da função analisada. Uma saída muito boa para esse problema é a utilização com função custo uma aproximação da negentropia.

3.1.6.1.5 Aproximação da Negentropia

Embora a negentropia seja teoricamente uma função aplicável nos problemas de BSS, o seu uso baseia-se na estimativa da função densidade de probabilidade dos sinais na saída da matriz de separação. Obviamente, esta estimativa nem sempre é fácil ou

possível. Sendo assim, o mais comum é utilizar aproximações da negentropia baseada na utilização direta dos dados nos sensores, para que seja construída uma função mais adequada e factível [50].

Momentos de ordem superior é um método clássico e muito utilizado para estimar a negentropia, como demonstra a Equação 3.38 [47],

$$N_g(y) = \frac{1}{12} [E\{y^3\}]^2 + \frac{1}{48} [Kurt\{y\}]^2. \quad (3.38)$$

Considera-se que na Equação 3.38 y tenha média nula e variância unitária, após passar pela etapa de pré-processamento como citado anteriormente; a confiabilidade dessa aproximação é limitada, pois o *Kurtosis* não apresenta robustez, podendo ser imprecisa e em muitas vezes sensíveis a *outliers*.

Com a intensão de minimizar esses problemas, novas técnicas foram desenvolvidas, como se pode verificar na Equação 3.39,

$$N_G(y) = \sum_{i=1}^p Q_i * [E\{g_i(y)\} - E\{g_i(v)\}]^2, \quad (3.39)$$

em que $g_i(.)$ são funções não-quadráticas adequadas, Q_i são constantes arbitrárias e v é uma variável gaussiana normalizada, ou seja, de média zero e variância unitária.

A escolha adequada de $g_i(.)$, faz com que a Equação 3.39 seja uma aproximação conceitualmente simples, computacionalmente ágil e com propriedades estatísticas interessantes, como a robustez em relação às funções que usam aproximações baseadas em momentos de ordem superior. Algumas funções mais utilizadas são:

$$g_1(u) = \frac{1}{Q_1} \log[\cosh(Q_1 u)] \quad (3.40a)$$

e

$$g_2(u) = -e^{\left(\frac{-u^2}{2}\right)}, \quad (3.40b)$$

em que $1 \leq Q_1 \leq 2$ é uma constante adequada.

A aproximação de negentropia é utilizada em vários algoritmos para encontrar a medida de não-gaussianidade, um dos principais é o FastICA [48].

3.1.6.2 Princípio de MaxEnt e InfoMax

Dentre vários princípios que podem ser utilizados para aplicação ao método de ICA, outro que se destaca é o princípio de INFOMAX (*Information Maximization*), ou seja, maximização da quantidade de informação ou entropia. Esse princípio é explicado sobre a visão de misturas convolutivas, ou seja, com saídas não lineares.

Este princípio foi proposto inicialmente baseando-se em redes neurais, como um método de treinamento não supervisionado, baseando-se na maximização da informação entre as entradas e saídas da rede neural. Um dos principais exemplos de aplicação do princípio de INFOMAX à separação de fontes baseou-se no método de treinamento não supervisionado [45].

Na Seção 3.1.6.1.2 do Capítulo 3, foi mostrado que as fontes são totalmente separadas quando as saídas do sistema de separação apresentam sinais independentes, o que é o mesmo que tornar a informação mútua nula.

Reanalizando a Equação 3.29, tem-se que:

$$I(y, x) = \Phi(y) - \Phi(z/x). \quad (3.41)$$

Onde o mapeamento entre x e y é determinístico²⁷, o conhecimento de uma variável determina completamente a outra e anula a entropia condicional. Assim, neste caso, tem-se:

$$I(y, x) = \Phi(y). \quad (3.42)$$

Nesta altura da análise é necessário o uso de uma transformação não linear sobre as saídas da matriz separação, pois uma vez que não existe restrição para $y = Wx$, a entropia de y não é limitada. Assim, considera-se a transformação não linear:

$$z = g(W)x, \quad (3.43)$$

em que,

$$g(y) = [g_1(y_1)g_2(y_2) \dots g_k(y_k)]^T, \quad (3.44)$$

e as funções $g_i(\cdot)$ são monotonicamente crescente, limitadas de tal maneira que $g_i(-\infty) = 0$ e $g_i(\infty) = 1$, tais como as funções típicas de ativação dos neurônios de RNA (Redes Neurais Artificiais) [61, 64].

Claramente, se escolha de $g_i(\cdot)$ for idêntica à função de distribuição cumulativa (f.d.c) da i -ésima fonte, que também possui a característica desejada de $g_i(-\infty) = 0$ e $g_i(\infty) = 1$, tem-se que:

²⁷ Considerado o caso sem ruído esta implicação é direta. No caso da presença de ruído, a mesma afirmativa é válida nos casos em que o ruído é passível e consequente separação dos sinais [45].

$$p_z(z) = U[0,1], \quad (3.45)$$

para,

- $z_i = a_i$, o que corresponde à identificação correta da fonte a_i , ou,
- $z_i = a_j, i \neq j$, o que corresponde à condição de indeterminação da recuperação com relação a uma permutação.

O método de igualar as densidades da entrada e saída através do uso de funções não lineares fornece uma adaptação de termos que forçam as f.d.p.'s o mais próximo possível da distribuição uniforme entre zero e um²⁸, ou seja, $p_z(z) = U[0,1]$ [45].

Esse processo baseado na maximização da entropia é conhecido como MaxEnt²⁹ [45, 70]. Analisando a Equação 3.42, maximizar a entropia é o mesmo que maximizar a informação mútua, assim este critério também é conhecido como InfoMax³⁰ [45, 70]. Este tipo de análise equivale ao de igualdade entre f.d.p.'s, aplicada em trabalhos de desconvolução não supervisionada, que serviram de base matemática desta área.

A derivação de um algoritmo adaptativo realizada [45], resultando na seguinte maneira:

$$\Delta W \propto (W^{-T})^{-1} - 2 * \tanh(Wx)x^T, \quad (3.46)$$

onde a função \tanh é aplicada separadamente em cada componente do vetor $y = Wx$ e

²⁸ Devido à função não linear que limita os valores entre zero e um.

²⁹ Do inglês, *Maximization of Entropy*.

³⁰ Do inglês, *Information Maximization*.

foi escolhida por ser a derivada da log-densidade da distribuição “logística” [45, 52]. Esta função comprovou-se adequada ao uso na estimação da maioria das distribuições super-gaussianas.

Será apontada aqui apenas uma dedução simplificada de como a equivalência entre os critérios (InfoMax/MaxEnt) pode ser visualizada. Uma prova mais detalhada é feita em [71].

Seja y a parte linear do sistema de separação, dado por:

$$y = Wx. \quad (3.47)$$

Assim, sabendo que $g(.)$ é inversível, tem-se, através do teorema de funções de v.a. [58]:

$$p_z(z) = \frac{p_y(y)}{|\prod_{i=1}^K g'_i(y_i)|}, \quad (3.48)$$

em que $g'_i(.)$ representa a derivada de $g_i(.)$. Assim, lembrando que $g_i(.)$ é não negativa, pode-se escrever a entropia de z como:

$$\Phi(z) = \Phi(y) + \ln[|\det(W)|] - E\{\ln[\prod_{i=1}^K g'_i(y_i)]\}. \quad (3.49)$$

Escrevendo-se a solução do critério InfoMax, ou MaxEnt, como função contraste, obtém-se:

$$\frac{\max}{W} (\Psi_{InfoMax}(W) = \ln[|\det(W)|] - E\{\ln[\prod_{i=1}^K g'_i(y_i)]\}). \quad (3.50)$$

3.1.6.3 Estimativa de Máxima Verossimilhança

A estimativa de Máxima Verossimilhança (MLE – *Maximum Likelihood Estimation*) é dos métodos mais conhecidos para se aplicar na estimação dos Componentes Independentes, e também ser equivalente à minimização da informação mútua [37, 53].

A estimação baseada em MLE é bastante utilizada por sua eficiência e variação mínima. Mas, como ponto negativo, a MLE precisa que as funções de densidade de probabilidade dos sinais de entrada sejam todas conhecidas, e como se sabe, nem sempre isso é possível; o que tem sido um grande desafio para os pesquisadores.

Com tudo, esse princípio (MLE) é muito utilizado para solucionar a questão da separação cega utilizando o método ICA. Considerando um modelo sem ruído aditivo, é possível determinar a verossimilhança e depois então, estimar os componentes independentes pela maximização da verossimilhança [37, 52, 72, 73].

O estimador ML é calculado buscando parâmetros que maximizem a verossimilhança das observações e frequentemente é mais prático e mais simples utilizar o logaritmo da verossimilhança. A utilização do logaritmo não causa nenhuma alteração, uma vez, que o máximo do logaritmo é obtido no mesmo ponto da máxima verossimilhança [9].

A função de verossimilhança para o modelo ICA é determinada usando a fórmula clássica do método jacobiano³¹ para transformações de funções densidade de

³¹ É a matriz formada pelas derivadas parciais de primeira ordem de uma função vetorial.

probabilidade (f.d.p.). Considerando o modelo ICA, determinado pela Equação 3.2, a densidade de p_x do vetor de misturas é dada por [49]:

$$p_x(x) = |detW| p_s(s) = |detW| \prod_i p_i(s_i), \quad (3.51)$$

onde $W = A^{-1}$ e p_i representa as densidades dos componentes independentes. Assim, equacionando $p_x(x)$ como função de $W = (w_1, w_2, \dots, w_n)^T$ e x , tem-se,

$$p_x(x) = |detW| \prod_i p_i(W_i^T x). \quad (3.52)$$

Considerando-se que existam T observações $x(1), x(2), \dots, x(T)$, a função de verossimilhança $L(W)$ pode ser determinada através do produto da densidade calculada nos T pontos:

$$L(W) = \prod_{t=1}^T \prod_{i=1}^n p_i(W_i^T x(t)) |detW| \quad (3.53)$$

e a função de log-verossimilhança é dada por:

$$\log L(W) = \sum_{t=1}^T \sum_{i=1}^n \log p_i(W_i^T x(t)) + T \log |detW|. \quad (3.54)$$

O termo $\log |detW|$ é derivado da regra clássica para transformação das variáveis aleatórias e suas densidades [58]. Para melhorar o entendimento e simplificar a notação pode-se substituir a soma sobre as amostras $x(t)$ pelo operador Esperança e dividir a expressão por T , obtendo-se:

$$\frac{1}{T} \log L(W) = E \left[\sum_{i=1}^n \log p_i(W_i^T x(t)) \right] + \log |\det W|, \quad (3.55)$$

considerando que na prática a Esperança usada nesta expressão é uma média calculada usando valores observados na amostra [49].

A questão neste tipo de abordagem é que frequentemente as densidades dos componentes independentes não são conhecidas. Uma solução de contornar essa questão é aproximá-las por uma família de densidades que são especificadas por um número limitado de parâmetros. É provado que é possível fazer a estimativa da distribuição dos componentes independentes a partir de apenas duas aproximações [37]. Para cada componente independente, somente é necessário determinar qual das duas aproximações é mais adequada (subgaussiana ou supergaussiana) através do cálculo de momentos não polinomiais e determinar aquela que melhor condiz com o critério de estabilidade adotado [49].

Por exemplo, é possível adotar as seguintes aproximações para os logaritmos de densidade supergaussianas e subgaussianas, respectivamente,

$$\log \tilde{p}_i^+(s) = \alpha_1 - 2 \log \cosh(s), \quad (3.56)$$

$$\log \tilde{p}_i^-(s) = \alpha_2 - \left[\frac{s^2}{2} - \log \cosh(s) \right], \quad (3.57)$$

onde α_1 e α_2 são constantes positivas escolhidas de modo a tornar estas duas funções logaritmos de densidades de probabilidade.

Definidas as densidades, para realizar a estimação da máxima verossimilhança

são necessários algoritmos que maximizem a função de verossimilhança. O algoritmo mais popular entre os existentes na literatura é o algoritmo Bell-Sejnowski [45]. Esse algoritmo consiste basicamente em calcular o gradiente da função de log-verossimilhança, Equação 3.55 dado por:

$$\frac{1}{T} \frac{\partial \log L}{\partial W} = (W^T)^{-1} + E[g(Wx)x^T], \quad (3.58)$$

onde $g(y) = (g_1(y_1), \dots, g_n(y_n))$ é um vetor contendo as derivadas das aproximações das distribuições dos componentes independentes $g_i(y_i) = (\log p_i)'$.

Com isso, a iteração para o algoritmo de estimação por máxima verossimilhança é dada por,

$$\Delta W \propto (W^T)^{-1} + E[g(Wx)x^T]. \quad (3.59)$$

Porém, este algoritmo converge lentamente em alguns casos devido à necessidade de inversão da matriz W a cada passo. Nos anos seguintes novas formulações desta ideia resultaram em algoritmos com melhor velocidade de convergência, por exemplo, com a utilização do gradiente natural na maximização da função de verossimilhança [49].

Como todo método de análise, este também, o MLE, apresenta considerações positivas e negativas na sua aplicação. As vantagens de seu uso, é que, sob condições regulares, são produzidos resultados eficientes, bem definidos pela teoria da estimação [52]. Como pontos negativos, desvantagens, os métodos que fazem uso de MLE,

apresentam:

- Necessita-se aplicar métodos mais complexos na análise dos sinais, uma vez que, é preciso conhecer, *a priori*, a densidade de probabilidade dos componentes independentes;
- Assim, como outros métodos, esse também, pode ser sensível a *outlier*, dependendo da f.d.p. escolhida.

3.2 Análise de Componentes Principais

Problemas matemáticos com alto grau de dimensão trazem muitas dificuldades, como o grande custo computacional e complexidade nas análises. Assim, um grande número de dimensões não significa necessariamente numa melhor análise dos dados, uma vez que, esses dados podem ser redundantes ou simplesmente, irrelevantes [74].

Desenvolver e aplicar um algoritmo de redução de dimensionalidade sanaria esses problemas, no entanto é muito importante, ou melhor, de suma importância, a atenção para que não se perca informações relevantes. Uma das técnicas mais utilizadas para realizar esse trabalho é a Análise de Componentes Principais (PCA – *Principal Component Analysis*).

Análise de Componentes Principais (PCA) consiste basicamente em um procedimento matemático que faz uso de uma transformação ortogonal de forma a transformar um conjunto de variáveis possivelmente correlacionadas em um conjunto não correlacionado chamado componentes principais. A execução dessa técnica é simples, realizando um mapeamento linear de forma que reduz a uma quantidade menor de dimensões comparado com as dimensões originais, de tal maneira que a variância desse novo conjunto seja maximizada [74].

Essa técnica (PCA) é muito utilizada para otimizar vários problemas semelhantes, aos quais é aplicado a técnica ICA, como foi citado anteriormente. Mas existe uma pequena diferença entre essas duas técnicas, na técnica ICA, obtêm-se sinais não gaussianos independentes e na técnica PCA, é obtido simplesmente sinais não correlacionados, sendo gaussiano ou não [51].

A PCA é uma técnica muito eficiente para se determinar variáveis não correlacionadas através de uma transformação linear, ela também é conhecida como transformada de *Karhunen-Loève* [75].

A PCA utiliza a correlação como medida, mas essa medida é considerada “fraca”. Assim, pode-se verificar que este procedimento permite a determinação de uma transformação linear da mistura. Considerando esse paradigma, é possível concluir que a PCA considera apenas estatística de segunda ordem, diferentemente de ICA, que considera estatística de ordem superior. Assim, utiliza-se a PCA como um pré-processamento ao ICA conhecido como branqueamento [76, 77].

Embora não solucione o problema de separação cega de fontes, a PCA pode ser vista como uma etapa de pré-processamento dos dados, que posteriormente serão separados dentre as diversas matrizes ortogonais, existe a matriz que não somente descorrelaciona os sinais, mas também os torna mutuamente independentes. Essa, por sinal, é a essência da técnica de Análise de Componentes Independentes [78].

3.3 Separação Cega de Fontes (BSS – *Blind Source Separation*)

Nesta seção, serão detalhados os princípios que se dizem respeito ao problema

de separação cega de fontes. Se constatado que é possível, a partir de hipóteses de que as fontes são independentes entre si e que possuem uma distribuição não – gaussiana, determinar um método para separação dos sinais originais.

3.3.1 Introdução da BSS

Os últimos anos dos especialistas em processamento de sinais têm sido muito agitados pelos estudos em recuperação de informação. Foi constatado que uma grande quantidade de aplicações decorrentes de outras áreas que, recentemente, vieram a incorporar o cenário de tratamento de informação. Dessa forma, problemas de desconvolução e separação atingiram um patamar interessante ao serem abordados de forma conjunta, possibilitando grandes avanços na comunidade de processamento de sinais [50].

As técnicas para processamento e análise de dados, com objetivo de recuperar, reconhecer ou separar fontes desconhecidas a partir unicamente dos sinais observados, obtidos por um conjunto de sensores, antenas ou microfones, recebem o nome de Processamento Cego de Sinais [9].

Em geral, a questão da BSS consiste em recuperar um conjunto de sinais, conhecidos como fontes, como demonstra a Figura 3.5.

O termo “cego” é usado para explicar o fato de que as fontes não são observadas diretamente, e que o sistema de mistura é desconhecido [78].

Os problemas ligados à ideia da separação cega de fontes são bastante rotineiros nos muitos ramos de estudo, indo desde o processamento de áudio, imagens até os

problemas de captação de estímulos cerebrais [79].




Figura 3.5 - Descrição geral separação cega de fontes [78].

A característica “cego” vem do fato que os sinais originais não são observados e de que não se tem nenhuma informação, a priori, do sistema de mistura a que esses sinais foram submetidos. Em relação às técnicas e algoritmos pode-se dizer que o adjetivo “cego” é devido do fato de não haver nenhum sinal de referência ou supervisão para direcionar o sistema de separação ou recuperação na execução de sua tarefa [9].

A separação cega de fontes tem como objetivo estimar componentes individuais mutuamente independentes por meio da observação de sinais obtidos por sensores. Tal tarefa é indispensável quando se trabalha com fontes que se encontram misturadas através de um modelo desconhecido e apenas misturas destas fontes de interesse estão disponíveis nos sensores de observações [31].

A falta de informação prévia das fontes não deve ser entendida como algo negativo para o modelo, ao contrário, visto que ela é a grande vantagem neste caso, uma vez que a torna uma ferramenta versátil na exploração da diversidade espacial gerada pelo número de sensores utilizados [80].

3.3.2 Histórico da BSS

O início da história do processamento cego de fontes iniciou-se nos anos 80 com

um trabalho desenvolvido na *Université de Grenoble*³², liderado por Christian Jutten. A motivação inicial surgiu a partir do estudo de trabalhos de processamento de sinais neurofisiológicos, em um modelo simplificado de movimento muscular codificado [50].

O resultado deste trabalho abriu outras vertentes, para outros trabalhos que a análise resultaria de uma mistura (não necessariamente linear) dos sinais.

Os primeiros passos das técnicas de separação cega de fontes caminharam com o auxílio das já então consolidadas técnicas baseadas em estatísticas de segunda ordem (*SOS – Second Order Statistics*), que possibilitavam uma quantidade de problemas solucionáveis bastante reduzidos devido às restrições impostas às fontes [50].

Apenas no final da década de 80 houve um avanço mais considerável na área de BSS, principalmente com Jean-François Cardoso e Pierre Comon. Esses dois nomes contribuíram fortemente como desenvolvimento e avanço matemático do tema através da exploração de duas linhas [81, 82]:

- Teoria da informação – a utilização da teoria elaborada por Claude Shannon foi crucial para permitir uma manipulação matemática e mostrar a factibilidade da solução do problema de BSS [50];
- Estatística de ordem superior (*HOS – Higher Order Statistic*) – a generalização de várias estratégias decorrentes do problema de desconvolução cega, que é uma simplificação do problema de BSS, possibilitou também um avanço das técnicas utilizadas para a separação de sinais [50].

Mas apenas em 1994, Pierre Comon, propôs uma nova abordagem para solucionar as barreiras até então impostas no problema da BSS. Ele comprovou que se

³² Universidade fundada em 1339 pelo delfin Humberto II, hoje é composta por seis universidades.

as fontes são independentes entre si, o sistema de separação deveria forçar as saídas a serem também independentes. Esta técnica ficou conhecida como análise de componentes independentes (*ICA – Independent Component Analysis*) [41].

3.3.3 Definição do Problema da BSS

Considere, inicialmente, o modelo para a solução do problema do processamento cego de sinais apresentado na Figura 3.6, onde se considera que um determinado número de sinais, determinados pela equação $S = [S_1, S_2, \dots, S_n]^T$, está sendo emitido, ou transmitido, por alguma fonte física através de um sistema de mistura, conhecido com matriz de mistura A . Os sinais, determinados pela equação $X = [X_1, X_2, \dots, X_m]^T$, além de sofrerem uma mistura entre os sinais das diferentes fontes, sofrem também, a influência de ruídos e interferências $V(k)$.

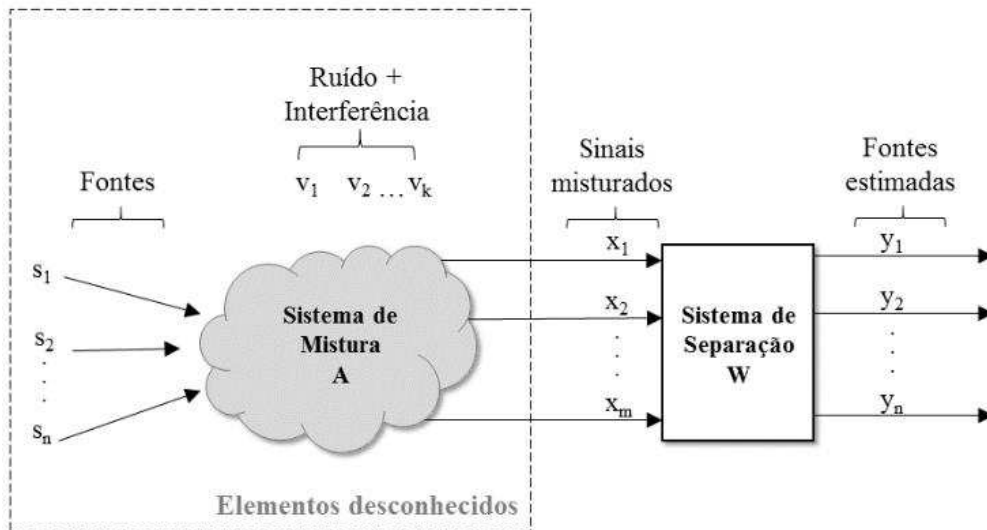


Figura 3.6 - Problema do processamento cego de sinais [9].

O problema do processamento cego de sinal é encontrar os sinais originais S a partir das medidas dos sensores X . A solução é extrair os sinais originais da mistura

através de um sistema W que forneça uma estimativa desses sinais dada por $Y = [Y_1, Y_2, \dots, Y_n]^T$.

No caso mais geral tratado pelo processamento cego de sinais, considera-se, portanto, m sinais misturados X . Estes sinais são combinados linearmente a partir de n sinais de fontes S , e do canal $A_{m \times n}$. Em geral, tem-se que $m > n$, e a presença de ruído dado por $V = [V_1, V_2, \dots, V_n]^T$. A formulação matemática do sistema da Figura 3.6 é caracterizada por $X = AS + V$ e $Y = WX$.

Uma consideração em relação ao sistema de mistura diz respeito à presença ou não de ruído. A definição de ruído é sempre problemática e, por isso, existem basicamente duas formas de considerar sua presença no sistema [9]. A primeira trata o ruído como uma fonte a ser separada das demais, considerando que ele é captado pelos sensores da mesma forma que demais fontes [38, 45]. A outra abordagem trata o ruído como elemento que deteriora e mistura e que, portanto, não deve ser recuperado [37, 83, 84]. A Figura 3.6 descreve esta última consideração.

3.4 Considerações Finais deste Capítulo

Este capítulo apresentou a fundamentação teórica dos temas predominantes da primeira parte desta tese. Inicialmente, foi introduzido o fundamento de Análise de Componentes Independentes (ICA) e algumas técnicas de pré-processamento aplicadas nesse tipo de análise, bem como algumas técnicas de determinação da ICA. Depois foi feito uma introdução sobre Análise de Componentes Principais (PCA), e finalizando foram apresentados os conceitos sobre Separação Cega de Fontes (BSS).

CAPÍTULO 4

ALGORITMO PROPOSTO

Este capítulo descreve detalhadamente o algoritmo proposto neste trabalho, bem como os algoritmos e métricas utilizados. A Taxa Máxima Sinal Ruído (*Maximum Signal-to-Noise Ratio*) e a Previsibilidade Temporal (*Temporal Predictability*) foram os algoritmos usados na elaboração do algoritmo proposto. A Taxa Sinal-Distorção (*SDR – Signal-Distortion Ratio*), a Taxa Sinal-Ruído (*SNR – Signal-to-Noise Ratio*) e a Taxa Sinal-Interferência (*SIR – Signal Interference Ratio*) foram as métricas aplicadas na saída do algoritmo proposto.

4.1 Introdução

A presente pesquisa tem como foco o problema do ruído presente nos sinais monitorados. Dessa forma ela tem como objetivo o desenvolvimento de um algoritmo que possa ser aplicado em situações gerais, na detecção e redução dos níveis de ruído inseridos em sinais monitorados. Tais ruídos podem ser gerados por diferentes tipos de fontes, sendo elas externas ou internas no equipamento de monitoramento.

Com tantas áreas de aplicação para esse tipo de algoritmo o ideal é que ele fosse desenvolvido de forma genérica. Que pudesse ser aplicado em qualquer área sem a necessidade de se estabelecer parâmetros para os dados de entrada, com isso o tornaria abrangente possível.

Para desenvolver esse algoritmo foram analisadas algumas tecnologias associadas a essa área do problema apresentado (ruído). O ideal era desenvolver uma aplicação diferente das tecnologias utilizadas na maioria dos equipamentos de

monitoramento que fazem uso de sistema ativo para eliminação de ruído. Estes equipamentos são compostos por dispositivos eletrônicos que geram ruídos, os quais são inseridos nos sinais monitorados.

A tecnologia utilizada para resolver as questões de geração de ruído e generalidade na aplicação foi a BSS. O algoritmo proposto trabalha sem gerar ruídos e também não necessita de parâmetros de entrada dos sinais monitorados, tornando-o uma solução simples para aplicações gerais. A BSS utiliza apenas análise estatística, não necessita de parâmetros das variáveis de entrada, e nem qualquer tipo de conhecimento a priori do sinal monitorado [9, 85].

Testes comparativos entre técnicas de eliminação de ruído já foram realizadas por alguns pesquisadores [86]. As técnicas de BSS e cancelamento de ruído adaptativo foram utilizadas nessa comparação. Os resultados experimentais demonstraram o desempenho mais robusto da técnica cega e, por sua vez, verifica a validade dessa técnica como uma ótima solução para esses problemas [86]. Assim, o algoritmo proposto está utilizando uma técnica consolidada neste tipo de aplicação.

A análise estatística realizada pela BSS é baseada na técnica de componentes independentes, a qual realiza a separação de forma muito eficaz de variáveis independentes [87]. A análise de componentes independentes realmente é muito eficiente no tratamento de ruídos [88]. A tecnologia escolhida pelo algoritmo proposto teve como base a característica acima, pois o sinal alvo a ser analisado se trata de variáveis aleatórias (ruído).

Uma solução para redução de ruído em sinais monitorados que também utiliza filtros ativos foi pesquisada. Relataram ainda, que esse tipo de técnica não é uma solução universal para tais problemas [89]. O algoritmo proposto realiza a redução dos ruídos, tanto os captados pelos sensores como também os gerados pelos equipamentos

de monitoramento. Esse processo de redução de ruído é feito de forma estatística, ou seja, sem utilizar qualquer equipamento eletrônico evitando geração de mais ruído. Ele ainda se apresenta como uma solução universal para qualquer aplicação em redução de ruídos, pois não necessita de nenhum parâmetro de entrada do sinal analisado.

Em equipamentos de monitoramento de EMG (eletromiografia) existem problemas na aquisição dos sinais. Estes problemas podem estar presentes nos materiais utilizados para fabricação dos sensores, que podem não apresentar as mesmas características ou em possíveis descalibrações do equipamento [90]. Capitando assim, sinais com uma pequena distorção. Para resolver esses problemas ele sugere a utilização de filtros digitais e filtros adaptativos como técnicas para eliminação desses ruídos [90]. Mais uma vez ocorre o problema da presença de ruído, porém a tecnologia aplicada ainda utiliza técnicas que fazem uso de componentes eletrônicos.

Muitos pesquisadores têm interesse nessa área de eliminação de ruído, por isso, existe uma quantidade muito grande em pesquisas propondo diversas soluções. Cada vez mais essas soluções tendem a utilizar técnicas que não fazem uso de circuitos eletrônicos [86, 87, 88, 91]. Assim o algoritmo proposto também segue essa tendência de evolução tecnológica.

O problema de presença de ruídos ocorre no monitoramento de estruturas civis, pois também utiliza equipamentos eletrônicos que fazem uso de sensores. Porém, este trabalho apresenta uma técnica de redução de ruído que não insere outros tipos de ruídos gerados pela utilização de componentes eletrônicos.

Existe uma crescente demanda de técnicas para realizar o monitoramento de estruturas civis, pois a maioria das existentes não são eficazes nos estágios iniciais de danos [92]. Assim, o algoritmo proposto se justifica com o intuito de apresentar uma técnica nova para realizar a redução de ruídos dos sinais monitorados em estruturas

civis, o qual pode ser aplicado nos estágios iniciais. Neste estágio os sinais possuem uma amplitude pequena (pequenas variações), com isso qualquer nível de ruído removido apresenta uma grande importância na eficiência do sinal analisado.

A técnica escolhida para o algoritmo proposto se justifica também pelo crescente estudo de redução de ruídos no processo de aquisição de sinais em tempo real [90, 93], por se tratar de algoritmo com baixa complexidade computacional [9]. Essa técnica utiliza, puramente, análise estatística dos sinais como é desejado [38, 52, 72, 94].

4.2 Arquitetura do Algoritmo Proposto

Inicialmente, aplica-se a BSS padrão nos sinais amostrados pelos sensores de monitoramento, identificado pelo vetor X , sendo composto pela mistura de partes dos sinais de cada sensor somado a um nível de ruído, onde esse ruído é representado por $V = [V_1, V_2, \dots, V_n]^T$.

Ressaltando, que os equipamentos utilizados atualmente para realizar o monitoramento podem não eliminar todos os níveis de ruído presentes na leitura pelos sensores, ou até mesmo, adicionar algum tipo de ruído característico do equipamento aos sinais, já que, estes equipamentos utilizam na sua maioria sistemas de eliminação de ruído baseado em filtros ativos.

A primeira etapa assume que o ruído é inerente ao sinal [37, 83, 84], não podendo ser separado do sinal, obtendo assim, somente o número de sinais correspondentes à mesma quantidade de sensores utilizados no monitoramento das estruturas civis, ou seja, o tamanho do vetor S é o mesmo do vetor Y , como mostrado na Figura 3.5. Ou seja, essa primeira etapa realiza a separação, o ordenamento dos sinais captados pelos sensores, uma vez que, nessa etapa o ruído é considerado inerente ao sinal, ele não é retirado dos sinais, pode ser visualizado na Figura 4.1.

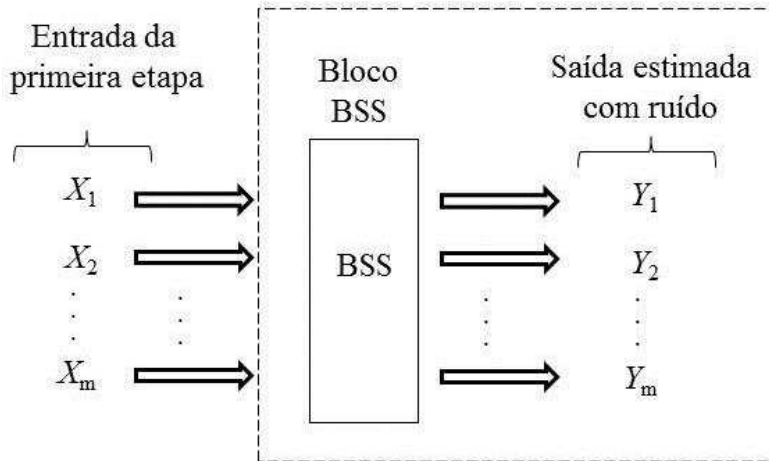


Figura 4.1 - Arquitetura da BSS padrão (primeira etapa do algoritmo proposto).

Na segunda etapa (algoritmo proposto), a aplicação da BSS é diferente da aplicação padrão, como na primeira etapa (onde têm-se m sinais de entrada e n sinais de saída, sendo $m = n$). A BSS é aplicada em cada sinal de entrada, cada sensor individual (primeiro no X_1 apenas, depois apenas no X_2 , e assim sucessivamente, e não no vetor X todo), de um sistema de monitoramento, ou seja, possui apenas um sinal de entrada e dois sinais de saída.

Nesta etapa, considera como entradas para a BSS as saídas da primeira etapa, sinais estimados com ruído. Ao contrário da BSS padrão a arquitetura proposta utiliza um único sinal de entrada mencionado acima, depois esse sinal é deslocado n unidades no tempo, criando assim, o segundo sinal de entrada. Aplica o algoritmo BSS utilizando esses dois sinais de entrada, assim, obtendo duas saídas, Y e V . Sendo o primeiro, o sinal estimado com ruído reduzido e o segundo, o ruído detectado presente no sinal X mostrado na Figura 4.2. Considera-se ruído nesse caso, sinais de fontes indesejadas e fontes ruidosas.

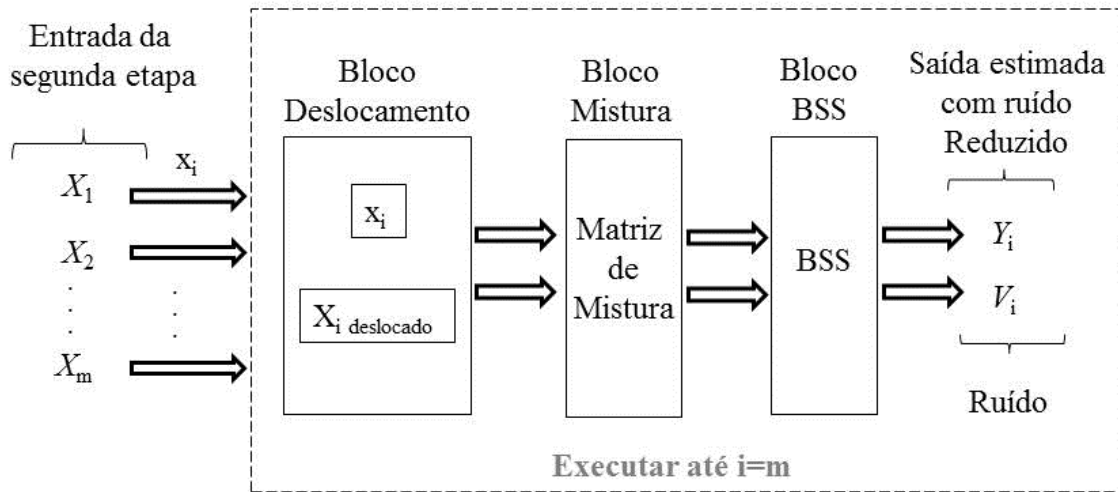


Figura 4.2 - Arquitetura do Algoritmo Proposto.

A análise é feita em sinais separados (individuais), com isso, pode ser aplicado quando o monitoramento possui apenas um único sensor, ou vários sensores distantes entre si, o que resulta em uma interferência praticamente nula entre os sensores, podendo considerar que em cada sinal existe apenas o sinal desejado e formas de ruídos não desejados, podendo assim, descartar a primeira etapa.

4.2.1 Estrutura Organizacional do Algoritmo Proposto

Nesta seção o algoritmo proposto será mostrado em diagrama de blocos, Figura 4.3, e cada bloco terá sua função detalhada.

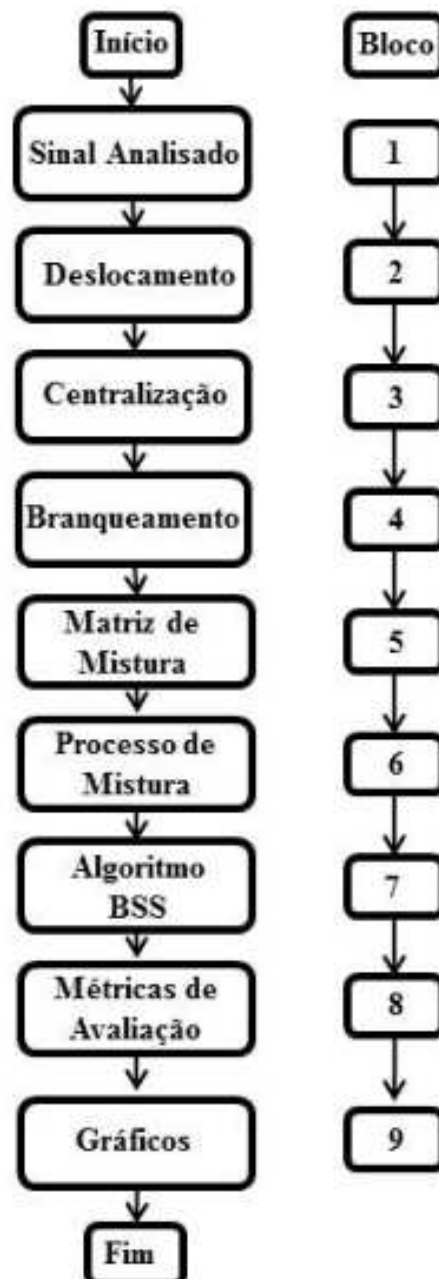


Figura 4.3 - Diagrama de blocos do algoritmo proposto.

Abaixo são detalhadas as funções de cada bloco do algoritmo proposto:

- Bloco 1 (Sinal Analisado): Seleção do sinal a ser analisado pelo algoritmo proposto $x_1(t)$;
- Bloco 2 (Deslocamento): Geração do segundo sinal $x_2(t)$, deslocando-se n amostras do sinal selecionado $x_1(t)$ no bloco 1. As amostras finais que se

encontram vazias, devido ao deslocamento são preenchidas com a média das últimas amostras existentes;

- Bloco 3 (Centralização): Calcula-se as médias $\tilde{x}_1(t)$ e $\tilde{x}_2(t)$ dos sinais de entrada, $x_1(t)$ e $x_2(t)$, e depois essas médias são subtraídas de seus respectivos sinais de entrada ($\dot{x}_1(t) = x_1(t) - \tilde{x}_1(t)$ e $\dot{x}_2(t) = x_2(t) - \tilde{x}_2(t)$), com isso, os sinais $x_1(t)$ e $x_2(t)$ ficam com média nula $\dot{x}_1(t)$ e $\dot{x}_2(t)$ [37, 38];
- Bloco 4 (Branqueamento): Calcula-se os desvios padrões $\sigma_1(t)$ e $\sigma_2(t)$ dos sinais de entrada, $\dot{x}_1(t)$ e $\dot{x}_2(t)$, e depois esses desvios padrões são divididos pelos seus respectivos sinais de entrada ($\dot{x}_1(t)$ e $\dot{x}_2(t)$), com isso, os sinais $\dot{x}_1(t)$ e $\dot{x}_2(t)$ ficam com variância unitária ($\ddot{x}_1(t)$ e $\ddot{x}_2(t)$) [37, 38];
- Bloco 5 (Matriz de Mistura): Seleciona-se uma matriz ($M \times M$) que pode ser uma matriz pré-determinada ou uma matriz gerada aleatória. Nas simulações foram usadas matrizes de mistura aleatória com a intenção de se aproximar mais da mistura real, ou seja, onde não se conhece essa matriz [38, 81, 82];
- Bloco 6 (Processo de Mistura): Realiza a mistura dos sinais $\ddot{x}_1(t)$ e $\ddot{x}_2(t)$ (sinal analisado e sinal deslocado) utilizando o princípio de mistura do problema BSS conforme a equação, $x = As$ [38, 81, 82];
- Bloco 7 (Algoritmo BSS): Escolha do algoritmo BSS a ser aplicado na separação cega dos sinais, pode ser selecionado o algoritmo: Previsibilidade Temporal ou Taxa Máxima Sinal Ruído [95, 96];
- Bloco 8 (Métricas de Avaliação): Nos sinais estimados y e v (sinal e ruído) são aplicadas as métricas de avaliação (SIR – Relação Sinal Interferência, SDR – Relação Sinal Distorção, SNR – Relação Sinal Ruído e Desvio Padrão), essa última é determinada nos sinais de perfilagem térmica [10, 97, 98];
- Bloco 9 (Gráficos): Esse último bloco gera os gráficos de todos os sinais

$(x_1(t), x_2(t), \dot{x}_1(t), \dot{x}_2(t), y(t), v(t) \text{ e } FDP(t))$, o último é o histograma do ruído estimado $v(t)$.

O gráfico resultante do cálculo do histograma de $v(t)$ teoricamente teria uma tendência para uma f.d.p. gaussiana, uma vez que esse tipo de função é característica de ruído [99]. Porém, o ruído ($v(t)$) encontrado pelo algoritmo pode ser composto por fontes ruidosas, mas também por fontes indesejadas, as quais não necessariamente possuem uma f.d.p gaussiana.

Ao executar essas dez etapas o algoritmo consegue estimar o sinal analisado e o ruído presente neste sinal.

4.3 Algoritmos de Análise da BSS

Nesta seção será explicado o fundamento teórico dos algoritmos (Previsibilidade Temporal e Taxa Máxima Sinal Ruído) utilizados para aplicar a BSS.

4.3.1 Algoritmo de Previsibilidade Temporal

A medida de Previsibilidade Temporal é definida e usada para separar sinais de misturas lineares. Para qualquer conjunto de sinais de fontes estatisticamente independentes tem-se a propriedade:

- Conjectura da Previsibilidade Temporal: A Previsibilidade Temporal de qualquer sinal misturado é menor, ou igual, que qualquer um dos seus sinais fontes originais.

Isto mostra que essa propriedade pode ser usada para recuperar os sinais fontes a

partir de um conjunto de misturas lineares desses sinais encontrando uma matriz de desmistura que maximiza a medida de Previsibilidade Temporal para cada sinal recuperado. Essa matriz é obtida como a solução para o problema do autovalor [100].

Considere um conjunto de K sinais fontes estatisticamente independentes $\mathbf{s} = (S_1, S_2, \dots, S_K)^T$. Um conjunto de $M \geq K$ misturas lineares $\mathbf{x} = (X_1, X_2, \dots, X_M)^T$ de sinais em \mathbf{s} pode ser formado com uma matriz de mistura A ($M \times K$): $\mathbf{x} = A\mathbf{s}$. Se os elementos de A são linearmente independentes, então qualquer sinal fonte \mathbf{s}_i pode ser recuperado de \mathbf{x} com uma matriz \mathbf{W}_i ($1 \times M$): $\mathbf{s}_i = \mathbf{W}_i\mathbf{x}$. A solução desejada aqui consiste em encontrar uma matriz de desmistura $\mathbf{W} = (\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_K)^T$ de modo que cada valor do vetor \mathbf{W}_i recupere um sinal diferente \mathbf{y}_i , onde \mathbf{y}_i é um valor estimado do sinal fonte \mathbf{s}_i , para sinais $K = M$.

O método para recuperar os sinais fontes é baseado na seguinte teoria, a previsibilidade temporal de um sinal mistura \mathbf{x}_i é usualmente menor que qualquer um dos sinais fontes que contribui para \mathbf{x}_i . Por exemplo, a forma de onda obtida pela soma de duas ondas senoidais com diferentes frequências é mais complexa do que qualquer uma das ondas senoidais originais [100].

Esse parâmetro é usado para definir a medida $F(\mathbf{W}_i, \mathbf{x})$ de previsibilidade temporal, o qual é usada para estimar a previsibilidade relativa de um sinal \mathbf{y}_i recuperado por uma matriz \mathbf{W}_i , onde $\mathbf{y}_i = \mathbf{W}_i\mathbf{x}$. Se sinais fontes são mais previsíveis do que misturas lineares \mathbf{y}_i desses sinais, então o valor de \mathbf{W}_i , o qual maximiza a previsibilidade de um sinal estimado \mathbf{y}_i , deve produzir um sinal fonte (i.e., $\mathbf{y}_i = c\mathbf{s}_i$, onde c é uma constante) [100].

A definição de previsibilidade de um sinal F é definida pela Equação 4.1:

$$F(\mathbf{W}_i, \mathbf{x}) = \log \frac{V(\mathbf{W}_i, \mathbf{x})}{U(\mathbf{W}_i, \mathbf{x})} = \log \frac{V_i}{U_i} = \log \frac{\sum_{\tau=1}^n (\bar{\mathbf{y}}_{\tau} - \mathbf{y}_{\tau})^2}{\sum_{\tau=1}^n (\tilde{\mathbf{y}}_{\tau} - \mathbf{y}_{\tau})^2}, \quad (4.1)$$

onde $\mathbf{y}_{\tau} = \mathbf{W}_i \mathbf{x}_{\tau}$ é o valor de um sinal \mathbf{y} no tempo τ , e \mathbf{x}_{τ} é um vetor de K valores de sinais misturas no tempo τ . O termo U_i reflete a extensão para qual \mathbf{y}_{τ} é previsto por uma média móvel de termo-curto $\tilde{\mathbf{y}}_{\tau}$ dos valores em \mathbf{y} . Ao contrário, o termo V_i é uma medida da variabilidade global de \mathbf{y} , assim \mathbf{y}_{τ} é previsto por uma média móvel de termo-longo $\bar{\mathbf{y}}_{\tau}$ dos valores em \mathbf{y} . Os valores previstos $\tilde{\mathbf{y}}_{\tau}$ e $\bar{\mathbf{y}}_{\tau}$ de \mathbf{y}_{τ} são ambos somas ponderadas exponencialmente de sinais medidos até o tempo $(\tau - 1)$, de tal modo que os valores recentes têm um coeficiente maior que aqueles no passado distante, veja a Equação 4.2:

$$\tilde{\mathbf{y}}_{\tau} = \lambda_S \tilde{\mathbf{y}}_{(\tau-1)} + (1 - \lambda_S) \mathbf{y}_{(\tau-1)} : 0 \leq \lambda_S \leq 1 \quad (4.2a)$$

$$\bar{\mathbf{y}}_{\tau} = \lambda_L \bar{\mathbf{y}}_{(\tau-1)} + (1 - \lambda_L) \mathbf{y}_{(\tau-1)} : 0 \leq \lambda_L \leq 1. \quad (4.2b)$$

A meia vida h_L de λ_L é muito maior (tipicamente 100 vezes maior) do que a meia vida h_S de λ_S . A relação entre a meia vida h e o parâmetro λ é definido como $\lambda = 2^{-\frac{1}{h}}$.

Note que maximizando somente V_i resultaria em um sinal de alta variância sem restrições da sua estrutura temporal. Ao contrário, minimizando somente U_i resultaria em um sinal DC³³. Em ambos os casos, soluções triviais podem ser encontradas para W_i porque V_i pode ser maximizada definindo a norma de W_i para ser grande, e U_i pode ser minimizando definindo $W_i = 0$. Ao contrário, a taxa V_i/U_i pode ser maximizada

³³ Fluxo unidirecional.

somente se as duas condições são ambas satisfeitas:

- a) y tem uma variação diferente de zero (i.e., alta variância);
- b) Os valores em y mudam lentamente ao longo do tempo.

Note também que o valor de F é independente da norma de W_i , de modo que apenas as alterações na direção de W_i afeta o valor de F .

Considere dois sinais fontes, ondas senoidais, s_1 e s_2 com o mesmo período de modo que $s_1 = s_2 + \pi$. O sinal mistura $s = s_1 + s_2$ é zero em todos os pontos de tempo e é, portanto, bastante previsível. Embora s seja intuitivamente previsível, a definição de previsibilidade F usada aqui é robusta. Especificamente, o valor da função F é indefinido para s porque se $s = 0$ em todos os pontos, então $V_i = U_i = 0$ e $F = \log \frac{0}{0}$. Por outro lado, se as frequências de s_1 e s_2 não são exatamente as mesmas, então o valor de F não é indefinido.

Para estimar um sinal individual deve-se considerar um sinal mistura escalar y_i formado pela aplicação de uma matriz W_i , de $1 \times M$, a um conjunto de sinais x de $K = M$. Dado que $y_i = W_i x$, a Equação 4.1 pode ser reescrita como [100]:

$$F = \log \frac{W_i \bar{C} W_i^T}{W_i \tilde{C} W_i^T}, \quad (4.3)$$

onde \bar{C} é uma matriz ($M \times M$) de covariâncias de termo-longo entre sinais misturas e \tilde{C} é a matriz de covariâncias de termo-curto. A covariância de termo-longo \bar{C}_{ij} e a covariância de termo-curto \tilde{C}_{ij} entre as misturas são definidas como:

$$\tilde{C}_{ij} = \sum_{\tau}^n (x_{i\tau} - \tilde{x}_{i\tau})(x_{j\tau} - \tilde{x}_{j\tau}) \quad (4.4a)$$

$$\bar{C}_{ij} = \sum_{\tau}^n (x_{i\tau} - \bar{x}_{i\tau})(x_{j\tau} - \bar{x}_{j\tau}) \quad (4.4b)$$

Note que \tilde{C} e \bar{C} precisam ser calculado apenas uma vez para um dado conjunto de sinais mistura e que os termos $(x_{i\tau} - \bar{x}_{i\tau})$ e $(x_{i\tau} - \tilde{x}_{i\tau})$ podem ser pré-calculados usando operações de convolução rápidas [101].

O gradiente ascendente de F em relação à \mathbf{W}_i pode ser usado para maximizar F , maximizando assim a previsibilidade de \mathbf{y}_i . A derivada de F em relação à \mathbf{W}_i é:

$$\nabla \mathbf{W}_i F = \frac{2\mathbf{W}_i}{V_i} \bar{C} - \frac{2\mathbf{W}_i}{U_i} \tilde{C}. \quad (4.5)$$

Para estimar todas as fontes simultaneamente existentes, o gradiente de F é zero na solução, assim a Equação 4.5 fica da seguinte maneira [95, 96]:

$$\mathbf{W}_i \bar{C} = \frac{V_i}{U_i} \mathbf{W}_i \tilde{C}. \quad (4.6)$$

Os extremos em F correspondem aos valores de \mathbf{W}_i que satisfaça a Equação 4.6, os quais tem a forma do problema generalizado dos auto-valores e auto-vetores [100]. As soluções para \mathbf{W}_i podem ser obtidas como auto-vetores da matriz $(\tilde{C}^{-1} \bar{C})$, com auto-valores $\gamma_i = \frac{V_i}{U_i}$ correspondentes. Como percebido acima, o primeiro auto-vetor define um máximo em F , e cada um dos auto-vetores remanescentes defines outros pontos em F .

A matriz \mathbf{W}_i pode ser obtida usando uma rotina para o problema generalizado de

eigenvalue (auto-valores). Os resultados presentes neste trabalho foram obtidos usando a função *eigenvalue* do Matlab, sendo $\mathbf{W} = \mathbf{eig}^{34}(\bar{\mathbf{C}}, \tilde{\mathbf{C}})$. Todos os K sinais podem ser então estimados por $\mathbf{y} = \mathbf{W}\mathbf{x}$, onde cada linha de \mathbf{y} corresponde a exatamente um sinal estimado \mathbf{y}_i [95].

4.3.1.1 Estrutura Organizacional do Algoritmo de Previsibilidade Temporal

Nesta seção o algoritmo de Previsibilidade Temporal será mostrado em diagrama de blocos, Figura 4.4, e cada bloco terá sua função detalhada.

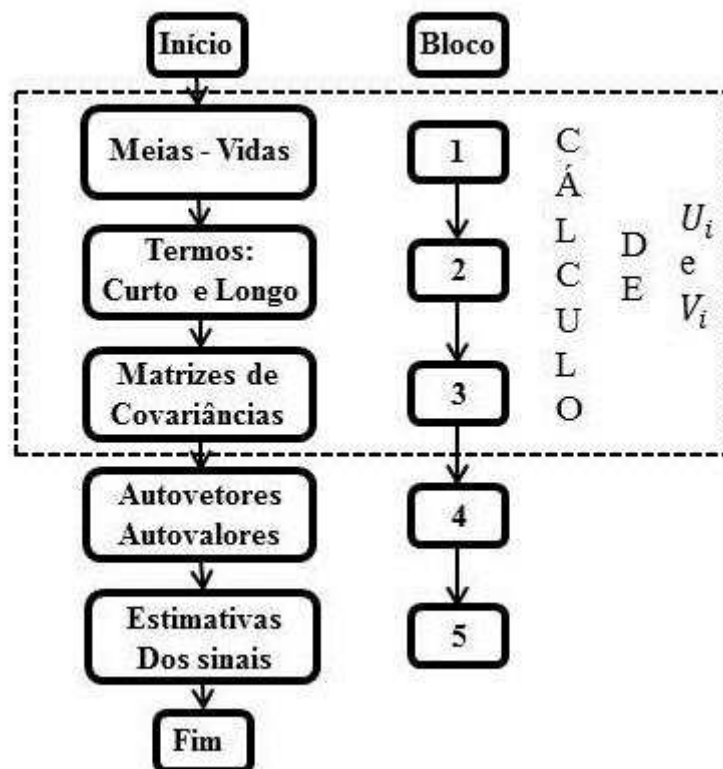


Figura 4.4 - Fluxograma do Algoritmo de Previsibilidade Temporal.

³⁴ Função Autovalor e Autovetor do Matlab.

Abaixo são detalhadas as funções de cada bloco do algoritmo de Previsibilidade Temporal:

- Bloco 1 (Meias – Vidas): Define os valores das meias – vidas, meia – vida longa (h_L) e meia – vida curta (h_S);
- Bloco 2 (Termos: curto e longo): Realiza o cálculo dos parâmetros λ , sendo para meia – vida curta ($\lambda_S = 2^{\frac{-1}{h_S}}$) e para meia – vida longa ($\lambda_L = 2^{\frac{-1}{h_L}}$), depois realiza o cálculo dos valores previstos $\widehat{\mathbf{y}}_{\tau}$ e $\overline{\mathbf{y}}_{\tau}$, de acordo com a Equação 4.2;
- Bloco 3 (Matrizes de covariâncias): aplica-se a função *cov*³⁵ do Matlab nos resultados do bloco 2, assim determinando as matrizes de covariâncias, covariância de termo – longo ($\bar{\mathcal{C}}_{ij}$) e covariância de termo – curto ($\tilde{\mathcal{C}}_{ij}$) segundo a Equação 4.4;
- Bloco 4 (Autovetores e Autovalores): aplica-se a função *eig* do Matlab no resultado do bloco 3 para determinar a matriz de desmistura (\mathbf{W}), como definido no último parágrafo da seção 4.3.1, $\mathbf{W} = \mathbf{eig}(\bar{\mathcal{C}}, \tilde{\mathcal{C}})$.
- Bloco 5 (Estimativas dos sinais): realiza a estimativa dos sinais, \mathbf{y} e \mathbf{v} (sinal e ruído) pela equação $\mathbf{y} = \mathbf{W}\mathbf{x}$.

Ao executar essas cinco etapas o algoritmo de Previsibilidade Temporal consegue-se estimar o sinal analisado e o possível ruído presente no sinal analisado.

4.3.2 Algoritmo Taxa Máxima Sinal Ruído

Esse algoritmo de separação cega de fontes é baseado na característica de que a

³⁵ Função matriz covariância do Matlab.

relação sinal-ruído (SNR) é máxima quando sinais fontes independentes estatisticamente são complementemente separáveis. Sinais fontes são substituídos por sinais estimados de médias móveis. A função de matrizes de covariância dos sinais fontes e ruídos é expressa pelo problema generalizado de auto-valores, e a matriz desmistura foi desenvolvida para resolver o problema generalizado dos auto-valores sem nenhuma interatividade. Assim, aplicando uma baixa complexidade computacional.

Alguns autores têm afirmado que nem sempre a previsibilidade temporal de um sinal mistura é menor, ou igual, a de seus sinais fontes [96]. Com isso, este trabalho também realizou o algoritmo Relação Máxima Sinal Ruído que é definida por uma função de relação sinal ruído.

Considerando todas as definições realizadas anteriormente sobre o problema da separação cega de fontes pode-se iniciar as definições desse algoritmo.

De acordo como modelo de separação cega de fontes, considera-se erro entre os sinais originais e os sinais estimados como ruído, assim, a fórmula da relação sinal ruído é:

$$SNR = 10\log \frac{s.s^T}{e.e^T} = 10\log \frac{s.s^T}{(s-y).(s-y)^T}. \quad (4.7)$$

Sinais originais \mathbf{s} são desconhecidos, por isso, é usado média móvel dos sinais estimados $\tilde{\mathbf{y}}$ em vez dos sinais originais \mathbf{s} . Com isso a Equação 4.7 pode ser reescrita:

$$SNR = 10\log \frac{s.s^T}{e.e^T} = 10\log \frac{\tilde{\mathbf{y}}.\tilde{\mathbf{y}}^T}{(\tilde{\mathbf{y}}-\mathbf{y}).(\tilde{\mathbf{y}}-\mathbf{y})^T}, \quad (4.8)$$

onde $\tilde{\mathbf{y}}(n) = \frac{1}{p} \sum_{j=0}^p \mathbf{y}(n-j)$ é a média móvel dos sinais estimados \mathbf{y} , p inteiro é o

tamanho da média móvel (p menor que 100). Para simplificar o cálculo, $\tilde{\mathbf{y}}$ no numerador é substituído por \mathbf{y} . A função custo relação sinal-ruído máxima é definida como:

$$F(\mathbf{y}) = SNR = 10 \log \frac{\mathbf{y} \cdot \mathbf{y}^T}{(\tilde{\mathbf{y}} - \mathbf{y}) \cdot (\tilde{\mathbf{y}} - \mathbf{y})^T} \quad (4.9)$$

onde $\mathbf{y} = \mathbf{W}\mathbf{x}$, $\tilde{\mathbf{y}} = \mathbf{W}\tilde{\mathbf{x}}$. Onde $\tilde{\mathbf{x}}$ é a média móvel dos sinais mistura \mathbf{x} , dado por:

$$\tilde{x}_i(n) = \frac{1}{p} \sum_{j=0}^p \mathbf{x}(n - j). \quad (4.10)$$

Otimizando a função custo, Equação 4.9 pode ser reescrita como [96]:

$$\begin{aligned} F(\mathbf{W}, \mathbf{x}) &= 10 \log \frac{\mathbf{y} \cdot \mathbf{y}^T}{(\tilde{\mathbf{y}} - \mathbf{y}) \cdot (\tilde{\mathbf{y}} - \mathbf{y})^T} = 10 \log \frac{\mathbf{W}\mathbf{x} \cdot \mathbf{x}^T \mathbf{W}^T}{\mathbf{W}(\tilde{\mathbf{x}} - \mathbf{x}) \cdot (\tilde{\mathbf{x}} - \mathbf{x})^T \mathbf{W}^T} \\ &= 10 \log \frac{\mathbf{W}\mathbf{C}\mathbf{W}^T}{\mathbf{W}\tilde{\mathbf{C}}\mathbf{W}^T} \\ &= 10 \log \frac{V}{U}. \end{aligned} \quad (4.11)$$

De acordo com a Equação 4.11, a derivada de F em relação à \mathbf{W} é:

$$\frac{\partial F}{\partial \mathbf{W}} = \frac{2\mathbf{W}_i}{V_i} \mathbf{C} - \frac{2\mathbf{W}_i}{U_i} \tilde{\mathbf{C}} \quad (4.12)$$

O gradiente da derivada de F em função de \mathbf{W} é zero obtendo novamente,

$\mathbf{W}_i \mathbf{C} = \frac{v_i}{u_i} \mathbf{W}_i \tilde{\mathbf{C}}$ [95, 96], a Equação 4.6.

Os resultados presentes neste artigo foram obtidos usando a função *eigenvalue* do Matlab, sendo $\mathbf{W} = \mathbf{eig}(\tilde{\mathbf{C}}, \mathbf{C}^{-1})$. Todos os K sinais podem ser então estimados por $\mathbf{y} = \mathbf{W}\mathbf{x}$, onde cada linha de \mathbf{y} corresponde a exatamente um sinal estimado \mathbf{y}_i , como no algoritmo de previsibilidade temporal.

4.3.2.1 Estrutura Organizacional do Algoritmo Taxa Máxima Sinal Ruído

Nesta seção o algoritmo Taxa Máxima Sinal Ruído será mostrado em diagrama de blocos, Figura 4.5, e cada bloco terá sua função detalhada.

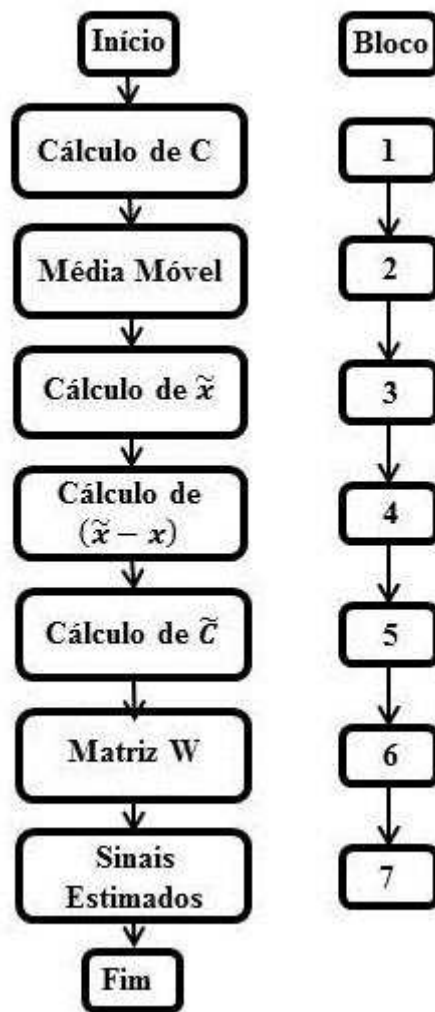


Figura 4.5 - Fluxograma do algoritmo Taxa Máxima Sinal Ruído.

Abaixo são detalhadas as funções de cada bloco do algoritmo de Previsibilidade Temporal:

- Bloco 1 (Cálculo de C): é determinada aplicando a função *cov* do Matlab nos sinais analisados (x);
- Bloco 2 (Média Móvel): especificação do tamanho da média móvel p (lembrando que deve ser menor que 100);
- Bloco 3 (Cálculo de \tilde{x}): utiliza-se a Equação 4.10 para determinar os valores de \tilde{x} , ou seja, média móvel dos sinais misturados x ;

- Bloco 4 (Cálculo de $(\tilde{x} - x)$): determina a diferença entre os valores da média móvel (\tilde{x}) e dos valores misturados originais (x);
- Bloco 5 (Cálculo de \tilde{C}): aplica-se a função *cov* do Matlab no resultado do bloco 4, ou seja, determina-se a covariância de $(\tilde{x} - x)$;
- Bloco 6 (Matriz W): aplica-se a função *eig* do Matlab em C e \tilde{C} , $W = \text{eig}(\tilde{C}, C^{-1})$, ou seja, W é determinado encontrando os autovetores e autovalores das matrizes C e \tilde{C} ;
- Bloco 7 (Sinais Estimados): realiza a estimativa dos sinais, y e v (sinal e ruído) pela equação $y = Wx$.

Ao executar essas sete etapas o algoritmo de Taxa Máxima Sinal Ruído estima o sinal analisado e o ruído presente neste sinal.

4.4 Métricas de Avaliação

Nesta seção será explicado o fundamento teórico das métricas (SIR – Relação Sinal Interferência, SDR – Relação Sinal Distorção e SNR – Relação Sinal Ruído) utilizadas para avaliar os sinais estimados pelo algoritmo proposto.

4.4.1 Relação Sinal Ruído (SNR) e Relação Sinal Distorção (SDR)

O método apresentado, a seguir, será aplicado em 2 (duas) medidas de performance, SDR (taxa sinal distorção) e SNR (taxa sinal ruído).

Os algoritmos utilizados com métricas para avaliar os resultados podem ser aplicados a todos os problemas de BSS. O sistema de mistura e a técnica de desmistura não precisam ser conhecidos.

As medidas de performance são encontradas para cada fonte estimada \hat{S}_j comparando-o com uma dada fonte original S_j . Se necessário, \hat{S}_j pode ser comparado com todas as fontes $(S_{j'})$ $1 \leq j' \leq n$ e as fontes originais podem ser seleccionadas como as que apresentam os melhores resultados.

O cálculo dos critérios envolvem dois passos sucessivos. No primeiro passo, o sinal estimado \hat{S}_j é decomposto conforme Equação 4.13,

$$\hat{S}_j = S_{target} + e_{interf} + e_{noise} + e_{artif}. \quad (4.13)$$

Onde $S_{target} = f(S_j)$ é uma versão de S_j modificada por uma distorção permitida $f \in F$ (onde F é um conjunto de distorções), e onde e_{interf} , e_{noise} e e_{artif} são, respectivamente, as interferências, ruído, e erro de artefatos. Esses quatro termos representam a parte de \hat{S}_j percebido como proveniente da fonte desejada S_j , de outras fontes indesejadas $(S_{j'})$ $j' \neq j$, e de ruídos (V_i) $1 \leq i \leq m$ [98]. No segundo passo, calculam-se as taxas de energia para avaliar cada um desses quatro termos.

Foi proposto um critério de performance para o caso mais usual, quando as distorções permitidas em Y_n são invariantes no tempo. Primeiro mostramos como decompor Y_n em quatro termos como na Equação 4.13, e então definimos as taxas de energia relevantes entre esses termos.

4.4.1.1 Decomposição de Fontes Estimadas por Projeções Ortogonais

Quando A é uma matriz instantânea invariante no tempo e quando a mistura é separada utilizando uma matriz instantânea invariante no tempo W , \hat{S}_j pode ser decomposto como:

$$\hat{S}_j = (WA)_{jj}S_j + \sum_{j' \neq j} (WA)_{jj'}S_{j'} + \sum_{i=1}^m W_{ji}V_i. \quad (4.14)$$

Assim, $(WA)_{jj}$ é um ganho invariante no tempo, parece natural identificar os três termos dessa soma como S_{target} , e_{interf} e e_{noise} , respectivamente (e_{artif} aqui é zero). Contudo, a Equação 4.14 não pode ser usada como uma definição de S_{target} , e_{interf} , e_{noise} , e e_{artif} uma vez que os sistemas de mistura e desmistura não são conhecidos. Também, os dois primeiros termos da Equação 4.14 não podem ser percebidas como objetos separados quando uma fonte não desejada $S_{j'}$ é altamente correlacionada com a fonte desejada S_j .

Com isso, a decomposição proposta é baseada na projeção ortogonal. Vamos denotar $\Pi\{y_1, \dots, y_k\}$ o projetor ortogonal sobre o subespaço gerado pelos vetores y_1, \dots, y_k . O projetor é uma matriz $T \times T$, onde T é o tamanho desses vetores. Consideram-se três projetores ortogonais:

$$P_{S_j} := \Pi\{S_j\}, \quad (4.15)$$

$$P_S := \Pi\{(S_{j'}) 1 \leq j' \leq n\}, \quad (4.16)$$

$$P_{S,V} := \Pi\{(S_{j'}) 1 \leq j' \leq n, (V_i) 1 \leq i \leq m\}. \quad (4.17)$$

As fontes estimadas \hat{S}_j são decompostas como a soma de quatro termos:

$$S_{target} := P_{S_j}\hat{S}_j, \quad (4.18)$$

$$e_{interf} := P_S\hat{S}_j - P_{S_j}\hat{S}_j, \quad (4.19)$$

$$e_{noise} := P_{S,V}\hat{S}_j - P_S\hat{S}_j, \quad (4.20)$$

$$e_{artif} := \hat{S}_j - P_{S,V}\hat{S}_j. \quad (4.21)$$

O cálculo de S_{target} é direto desde que envolva somente um produto inteiro simples: $S_{target} = \langle \hat{S}_j, S_j \rangle S_j / \|S_j\|^2$. O cálculo de e_{artif} é um pouco mais complexo. Se as fontes são mutuamente ortogonais, então $e_{artif} = \sum_{j' \neq j} \langle \hat{S}_j, S_{j'} \rangle S_{j'} / \|S_{j'}\|^2$. Por outro lado, se for usado um vetor de coeficientes \mathbf{C} tais que $P_S\hat{S}_j = \sum_{j'=1}^n \bar{\mathbf{C}}_{j'} S_{j'} = \mathbf{C}^H \mathbf{S}$ (onde $(.)^H$ denota Transposição Hermitian), então $\mathbf{C} = \mathbf{R}_{SS}^{-1} [\langle \hat{S}_j, S_1 \rangle, \dots, \langle \hat{S}_j, S_n \rangle]^H$, onde \mathbf{R}_{SS} é a matriz Gram das fontes definidas por $(\mathbf{R}_{SS})_{jj'} = \langle S_j, S_{j'} \rangle$. O cálculo de $P_{S,V}$ procede de forma similar; entretanto, a maioria das vezes pode assumir que os sinais de ruído são mutuamente ortogonais e ortogonais a cada fonte, de modo que $P_{S,V}\hat{S}_j \approx P_S\hat{S}_j + \sum_{i=1}^m \langle \hat{S}_j, V_i \rangle V_i / \|V_i\|^2$ [98].

4.4.1.2 Da Decomposição de Fontes Estimadas para Medidas de Performance

Global

Iniciando a partir da decomposição de \hat{S}_j das Equações (4.15 até 4.21), podemos definir critérios de performance numéricos pelo cálculo das taxas de energias expressas em decibéis. Definimos taxa de sinal distorção como:

$$SDR = 10 \log_{10} \frac{\|S_{target}\|^2}{\|e_{interf} + e_{noise} + e_{artif}\|^2} \quad (4.22)$$

e a taxa de sinal ruído como:

$$SNR = 10\log_{10} \frac{\|s_{target} + e_{interf}\|^2}{\|e_{noise}\|^2}. \quad (4.23)$$

4.4.2 Relação Sinal Interferência (SIR)

Para analisar outra grandeza de performance, a SIR (taxa sinal-interferência) foi utilizada uma técnica diferente [97], descrita abaixo. A entrada SIR , SIR^{in} , mede a performance de sinais misturados antes de eles serem processados pelo algoritmo proposto. Seja x_i a observação do canal i com a Equação 4.24,

$$x_i = \sum_{j=1}^m a_{i,j} s_j + v_i, \quad (4.24)$$

onde $a_{i,j}$ denota os coeficientes de misturas, s_j é a fonte original, e v_i demonstra o ruído, e m é o número de fontes. SIR^{in} calcula a taxa dos k 's sinais fontes $a_{i,k} s_k$ como pode observar na Equação 4.25,

$$SIR_k^{in}(i) = 10\log_{10} \frac{a_{i,k}^2 \|s_k\|^2}{\|x_i - a_{i,j} s_k\|^2}. \quad (4.25)$$

Quando todas as n amostras são consideradas, a SIR_k^{in} máxima, é definida pela Equação 4.26,

$$SIR_k^{in} = \max_{i=1,\dots,n} SIR_k^{in}(i). \quad (4.26)$$

É usada a mesma abordagem para definir a saída SIR , SIR^{out} . Seja \hat{A}_o e \hat{S}_o , respectivamente, a matriz mistura e os sinais fontes derivados do método BSS; e seja, A

e S , a matriz mistura verdadeira e os sinais fontes, respectivamente. A ordem dos sinais fontes estimados em \hat{S}_o pode ser alterada para corresponder em S para resolver o seguinte problema de otimização,

$$P_o = \arg \min_P \|S - P^T \hat{S}_o\|_F^2, \quad (4.27)$$

onde P é uma matriz permutação. Assim, é definido $\hat{A} = \hat{A}_o P_o$ e $\hat{S} = P_o^T \hat{S}_o$ como matriz mistura estimada e sinais fontes, respectivamente. SIR^{out} calcula a taxa dos k 's sinais $a_{i,k} s_k$ derivado da solução BSS como na Equação 4.28,

$$SIR_k^{out}(i) = 10 \log_{10} \frac{a_{i,k}^2 \|s_k\|^2}{\|a_{i,k} s_k - \hat{a}_{i,j} \hat{s}_k\|^2}, \quad (4.28)$$

onde $\hat{a}_{i,j}$ e \hat{s}_k são $a_{i,j}$ e s_k estimados em \hat{A} e \hat{S} , respectivamente. Define-se também a saída SIR máxima para um sinal fonte k como,

$$SIR_k^{out} = \max_{i=1,\dots,n} SIR_k^{out}(i). \quad (4.29)$$

Assim, o SIR para o sinal fonte k é,

$$SIRI_k = SIR_k^{out} - SIR_k^{in}, \quad (4.30)$$

e o SIR médio para todos os sinais fontes é:

$$SIRI = \frac{1}{m} \sum_{k=1}^m SIRI_k. \quad (4.31)$$

4.4.2.1 Estrutura Organizacional da Métrica Relação Sinal Interferência (SIR)

Nesta seção a métrica relação sinal interferência (SIR) será mostrada em diagrama de blocos, Figura 4.6, e cada bloco terá sua função detalhada.

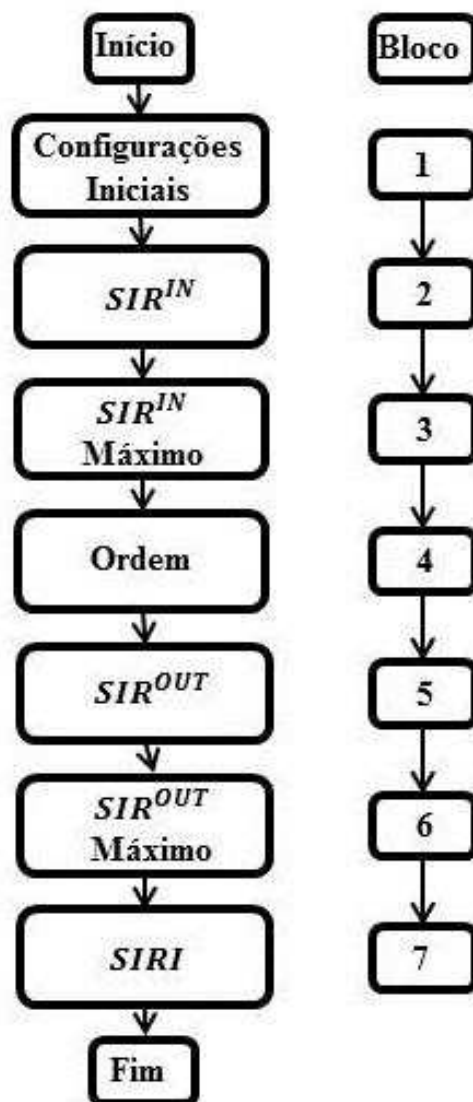


Figura 4.6 - Fluxograma da métrica relação sinal interferência (SIR).

Abaixo são detalhadas as funções de cada bloco da métrica relação sinal interferência (SIR), como foram implementadas no algoritmo (Matlab):

- Bloco 1 (Configurações Iniciais): Estabelece os tamanhos das variáveis: fontes, misturas e fontes estimadas usando a função *size* do Matlab ($size = (x)$), onde x são os sinais misturados. Estabelece os tamanhos das variáveis: matriz de mistura e matriz de desmistura usando a mesma função do Matlab (*size*), igual a ($size = (A)$), onde A é a matriz de mistura inicial;
- Bloco 2 (SIR^{IN}): realiza o cálculo do SIR de entrada usando como referência a Equação 4.25, o cálculo gera uma matriz quadrada “SIR_IN” de mesmo tamanho do vetor dos sinais misturados (x). O coeficiente $a_{i,k}^2$ é representado pelos componentes da matriz de mistura (A), o termo $\|s_k\|$ é calculado aplicando a função *norm*³⁶ do Matlab nos sinais originais (antes da mistura), esse termo resulta no numerador da Equação 4.25. O denominador da Equação 4.25 ($\|x_i - a_{i,k}s_k\|$) foi determinado aplicando a função *norm* do Matlab no resultado: sinais misturados (x) subtraído da multiplicação da matriz de mistura (A) com sinais originais (antes da mistura);
- Bloco 3 (SIR^{IN} Máximo): seleciona os valores máximos de SIR^{IN} determinado no bloco 2 aplicando a função *max*³⁷ do Matlab, terminando em um vetor do tamanho do vetor dos sinais misturados (x);
- Bloco 4 (Ordem): Ordena o vetor dos sinais originais (antes da mistura)

³⁶ É uma função que atribui um comprimento estritamente positivo para cada vetor.

³⁷ É uma função que seleciona os componentes maiores.

com o vetor dos sinais estimados, para que esses vetores fiquem na mesma ordem, conforme a Equação 4.27. Inicialmente, determina-se uma matriz quadrada de índice do tamanho do vetor de sinais misturados (x) aplicando a função *norm* do Matlab no resultado da subtração do valor absoluto dos sinais originais (antes da mistura) com o valor absoluto dos sinais estimados (y). Após isso, aplica-se a função *min*³⁸ na matriz quadrada determinada anteriormente, assim encontrando os sinais estimados novos;

- Bloco 5 (SIR^{OUT}): calcula-se o SIR de saída, ou seja, após a aplicação do algoritmo proposto utilizando a Equação 4.28, o cálculo gera uma matriz quadrada “SIR_OUT” de mesmo tamanho do vetor dos sinais misturados (x). O coeficiente $a_{i,k}^2$ é representado pelos componentes da matriz de mistura (A), o termo $\|s_k\|$ é calculado aplicando a função *norm*³⁹ do Matlab nos sinais originais (antes da mistura), esse termo resulta no numerador da Equação 4.29. O denominador da Equação 4.29 ($\|a_{i,k}s_k - \hat{a}_{i,k}\hat{s}_k\|$) foi determinado aplicando a função *norm* do Matlab no argumento $a_{i,k}s_k - \hat{a}_{i,k}\hat{s}_k$, onde $a_{i,k}$ é a matriz de mistura (A), s_k são os sinais originais (antes da mistura), $\hat{a}_{i,k}$ é a matriz inversa de W , ou seja é inversa da matriz de desmistura encontrada pelo algoritmo proposto e \hat{s}_k são os sinais estimados organizados no bloco 4;
- Bloco 6 (SIR^{OUT} Máximo): seleciona os valores máximos de SIR^{OUT} determinado no bloco 5 aplicando a função *max* do Matlab, terminando em um vetor do tamanho do vetor dos sinais misturados (x);

³⁸ É uma função que determina os mínimos valores.

³⁹ É uma função que atribui um comprimento estritamente positivo para cada vetor.

- Bloco 7 (*SIRI*): determina o ganho de SIR realizando a subtração do SIR_k^{OUT} com o SIR_k^{IN} , conforme Equação 4.30, e também o ganho SIR médio conforme Equação 4.31.

4.5 Considerações Finais deste Capítulo

Este capítulo apresentou a fundamentação teórica dos tipos de algoritmos utilizados para operação do algoritmo proposto bem como alguns algoritmos de métricas de performance dos resultados. Inicialmente, foi introduzido o algoritmo de Relação Máxima Sinal Ruído e logo depois o algoritmo de Previsibilidade Temporal. Esses dois algoritmos foram aplicados para realizar a operação do algoritmo proposto neste trabalho. Em sequência, métricas de performance foram detalhadas, inicialmente a Relação Sinal Ruído (SNR) e Relação Sinal Distorção (SDR) e finalmente, a Relação Sinal Interferência (SIR).

CAPÍTULO 5

SINAIS ANALISADOS

Neste capítulo serão apresentados os sinais utilizados na análise do algoritmo proposto, definindo-os e caracterizando quais as formas de geração e captação desses sinais.

5.1 Ensaio Prático com Extensômetros

Nesta seção são demonstrados os sinais aplicados ao algoritmo proposto captados pela execução de uma simulação prática realizada no laboratório da Escola de Minas⁴⁰ da Universidade Federal de Ouro Preto⁴¹.

5.1.1 Introdução

Essa simulação prática foi realizada com intuito de coletar dados sobre o funcionamento de extensômetros resistivos para que houvesse a possibilidade de analisar a presença e influência de ruídos nos sinais monitorados por esses dispositivos, visto que eles são amplamente utilizados em várias áreas de estudo como: construção civil [1, 2], em biomedicina e geofísica [3].

A simulação prática foi implementada no espaço físico da Escola de Minas na Universidade Federal de Ouro Preto – Minas Gerais, entre os meses de outubro e

⁴⁰ Instituição de ensino superior de engenharia e arquitetura, localizada na cidade mineira de Ouro Preto, fundada em 12 de outubro de 1876, pelo cientista francês Claude Henri Gorceix.

⁴¹ Instituição de ensino superior pública federal brasileira, sediada em Ouro Preto, no estado de Minas Gerais. Criada em 21 de agosto de 1969 a partir da incorporação de duas centenárias instituições de ensino superior: a Escola de Farmácia fundada em 1839 e a Escola de Minas.

novembro de 2015, mais especificamente, no laboratório de estruturas. Durante esse período todas as montagens dos protótipos foram acompanhados por técnicos capacitados do laboratório de estruturas da Escola de Minas, demonstrando os métodos mais corretos para realizar a aquisição de sinais utilizando extensômetros.

5.1.2 Protótipo da Estrutura de Análise dos Extensômetros

O protótipo que foi utilizado para realizar a simulação prática foi montado usando uma estrutura capaz de aguentar a tensão proposta, com isso a deformação da estrutura estaria dentro da faixa elástica do material utilizado. Essa estrutura foi uma chapa de aço homogênea para que a deformação seja igual em uma mesma linha de ação das tensões.

Os extensômetros resistivos foram fixados a esta estrutura de maneira que eles executaram o monitoramento da deformação da mesma linha de ação, assim os sinais monitorados pelos extensômetros devem ser iguais, visto que monitoram o mesmo ponto.

Os extensômetros resistivos utilizados foram da marca Kyowa⁴², modelo KFG-5, de 5 mm de comprimento, resistência interna de $119,8 \pm 0,2 \text{ Ohms}$, com fator gage de $2,11 \pm 0,1 \%$, a estrutura foi montada usando a configuração quarto-de-ponte. O dispositivo físico usado para captar os sinais monitorados pelos extensômetros foi o *Spider8* da marca HBM⁴³ (Hottinger Baldwin Messtechnik) possuindo uma Relação Sinal Ruído (SNR) de 7 dB's [102]. O software utilizado pelo dispositivo foi *catman* versão 4.5 também da fabricante HBM [102].

⁴² Empresa japonesa fundada em 1949 na cidade de Shinjuku.

⁴³ Empresa atuante nas áreas de teste e medição fundada em 1950 na Alemanha.

5.1.3 Sinais Analisados

A estrutura foi exposta a vários níveis de tensão, iniciando sem carga nenhuma e aos poucos a carga foi sendo acrescentada até chegar ao nível máximo de tensão. Depois as cargas foram sendo retiradas diminuindo a tensão na estrutura até zerar novamente.

O procedimento acima foi repetido várias vezes em todas as configurações dos cabos (Tabela 5.1) usados para ligar os extensômetros ao dispositivo *spider* de monitoramento, com a intenção de inserir diferentes níveis de ruído nas leituras monitoradas por esse equipamento. As configurações foram alternadas utilizando dois cabos, um de 5 metros e o outro de 30 metros de comprimento. A disposição dos cabos também foram alternadas, sendo possível conectar esticado ou enrolado.

A Tabela 5.1 demonstra todas as configurações aplicadas nas análises práticas e também indica os níveis de ruídos teóricos entre os dois extensômetros usados em cada ensaio.

Tabela 5.1 - Relação da configuração dos ensaios e nível teórico de ruído.

Número do Ensaio	Entrada do Equipamento	Comprimento do Cabo		Disposição do Cabo		Nível de Ruído Teórico
		Curto	Longo	Retilíneo	Enrolado	
Ensaio 1	Extensômetro 1	X			X	Maior
	Extensômetro 2	X		X		Menor
Ensaio 2	Extensômetro 1	X			X	Menor
	Extensômetro 2		X		X	Maior
Ensaio 3	Extensômetro 1	X		X		Menor
	Extensômetro 2		X		X	Maior
Ensaio 4	Extensômetro 1	X		X		Menor
	Extensômetro 2		X	X		Maior
Ensaio 5	Extensômetro 1		X		X ⁴⁴	Maior
	Extensômetro 2	X		X		Menor
Ensaio 6	Extensômetro 1		X	X		Menor
	Extensômetro 2		X		X	Maior

Todos os sinais foram gerados usando a mesma sequência de tensões como citado anteriormente, porém com configurações dos cabos diferentes, resultando em seis sinais analisados de acordo com a Tabela 5.1. A Figura 5.1 mostra o comportamento geral dos sinais monitorados pelo dispositivo, a configuração dos cabos nesse ensaio em específico foram os dois do mesmo tamanho (5 metros) e os dois esticados.

⁴⁴ Esse experimento foi submetido à presença de um ímã em movimento dentro da circunferência do cabo enrolado.




Figura 5.1 - Curva caraterística dos ensaios experimentais realizados pelo autor.

5.2 Modelo Experimental e Numérico

Nesta seção será descrito outro conjunto de sinais analisados pelo algoritmo proposto. Um sinal monitorado através de um ensaio prático utilizando estruturas metálicas e outro sinal gerado por um modelo matemático representando o comportamento do ensaio prático realizado.

5.2.1 Introdução

Tanto o ensaio prático quanto o modelo matemático⁴⁵ foi realizado por Nunes (2012) [11] na Escola de Minas da Universidade Federal de Ouro Preto como parte de sua pesquisa para mestrado em Engenharia Civil.

O estudo dele foi feito em ligações soldadas do tipo “T”, “K” com afastamento e

⁴⁵ Modelo matemático construído usando a tecnologia de elementos finitos [114].

“KT” com afastamento, formadas por perfis tubulares estruturais de aço sem costura, com seção transversal retangular no banzo e circular no montante e nas diagonais.

Foram desenvolvidos modelos numéricos sendo realizado um estudo de refinamento de malha e de condições de contorno visando a definição do modelo mais eficiente para as análises. Os modelos numéricos foram calibrados com resultados experimentais obtidos em estudos anteriores realizados no Laboratório de Estruturas do Departamento de Engenharia Civil da Escola de Minas da Universidade Federal de Ouro Preto. No estudo numérico foi feito uma avaliação de refinamento de malha que possibilitou gerar modelos com número adequado de elementos e baixo custo computacional, e também foi avaliada a influência das condições de contorno nos resultados do modelo. Na calibração, os modelos numéricos tiveram uma ótima correlação quando comparados como os modelos experimentais, validando o estudo paramétrico das ligações [11].

No Brasil, há uma crescente demanda por construção metálica usando perfil tubulares devido às grandes vantagens, como, alta resistência à torção, cargas axiais e aos efeitos combinados. Sem contar com os aspectos de desenvolvimento, estética e modernidade que podem ser planejados [11].

As ligações entre tubos podem ser feita de várias maneiras, atualmente, essas ligações são classificadas de acordo com a forma e o tipo de carregamento [11].

Com relação à forma, os tipos de ligações soldadas entre tubos podem ser classificados como tipo: “T”, “X”, “Y”, “K”, “N” e “KT”, conforme a Figura 5.2.




Figura 5.2 - Classificação da tipologia das ligações de treliças planas devido à forma [11].

5.2.2 Ensaio Prático

A metodologia de ensaio, esquema de instrumentação e sinais monitorados são descritos nessa seção. Os ensaios realizados por Nunes (2012) [11] foram feitos em três protótipos com dois ensaios em cada, eles foram identificados como T02 e T03 de uma ligação “T”, K01-B e K03-B de uma ligação “K”, e KT01 e KT03 de uma ligação “KT”. As Figuras 5.3, 5.4 e 5.5 mostram os esquemas de montagem e suas respectivas montagens.





Figura 5.3 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "T" [11].




Figura 5.4 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "K" [11].





Figura 5.5 - Dimensões dos protótipos e esquemas gerais dos protótipos para ligação "KT" [11].

5.2.3 Sinais Analisados

Como relatado na seção anterior foram monitorados seis sinais nos ensaios práticos, para a análise neste trabalho foi selecionado o sinal que obteve o maior valor de correlação entre sinal prático e seu correspondente numérico. As Figuras 5.6 e 5.7 mostram os sinais utilizados pelo algoritmo proposto, sinal experimental e seu respectivo sinal numérico.




Figura 5.6 - Ensaio prático selecionado por obter a correlação mais alta [11].




Figura 5.7 - Sinal numérico correspondente ao ensaio prático da figura 4.6 [11].

5.3 Ensaio Prático com Sondas Térmicas

Nesta seção são demonstrados os sinais aplicados ao algoritmo proposto captados por sondas térmicas, caracterizando assim, o que é conhecido como perfilagem térmica.

5.3.1 Introdução

As características físico-químicas atuais do interior da Terra são fortemente vinculadas à forma com que a distribuição de temperatura e o fluxo de energia térmica se manifesta no seu interior [10].

O conhecimento do regime térmico atual das principais placas tectônicas, e dos vários processos de transferência de calor que operam no seu interior é fundamental para o estudo da dinâmica e da evolução do nosso planeta, e constitui por isso, um dos objetivos da Geotermia moderna [10].

Perfilagem é o levantamento completo de perfis referentes aos poços de água ou petróleo. O perfil de um poço é a imagem visual, em relação à profundidade, de uma ou mais características ou propriedades das rochas perfuradas. Existem vários processos físicos de medição (perfis).

Através da perfilagem pode-se mapear o poço com gráficos ou figuras que indicam áreas de interesse a serem exploradas. Existem vários tipos de perfilagens, por exemplo, a perfilagem elétrica que pode-se caracterizar vários tipos de perfis, como: Raios Gama, indução, sônico, densidade, etc.

Neste trabalho será utilizada a perfilagem térmica, caracterizando o perfil de temperatura. A caracterização da temperatura é muito importante para estabelecer uma boa perfilagem de poços. Com isso é possível determinar algumas variáveis importantes como fluxo de calor e gradiente térmico [103].

Essas variáveis podem sofrer alterações devido à presença de convecções de fonte de água natural. Assim, é importante a análise e o monitoramento adequado da perfilagem dos poços, necessitando que o sinal analisado seja o mais fiel possível do real. Por esse motivo é importante a redução ou até mesmo a eliminação de qualquer tipo de ruído presente nos dados monitorados pelas sondas de perfilagem.

As sondas profissionais utilizadas para caracterizar os perfis de poços são extremamente caras, o que torna sua utilização por entidades públicas de ensino e pesquisa praticamente impossível. Assim, a proposta neste trabalho tem a finalidade de tornar os perfis caracterizados por essas entidades mais reais, reduzindo os ruídos, uma vez que elas utilizam sistemas de caracterização de perfis não profissionais.

As informações sobre temperaturas em subsuperfície constituem o acervo básico para avaliação de recursos geotermiais. Geralmente há dois conjuntos de informações sobre as temperaturas em profundidade: medidas diretas e estimativas indiretas [104,

105, 106, 107, 108].

A arquitetura proposta utilizou alguns sinais de perfilagem térmica de poços (temperatura) captados por um protótipo de sonda em várias cidades brasileiras [10].

Nesse conjunto de sinais foram aplicados os algoritmos de Taxa Máxima Sinal Ruído [96] e Previsibilidade Temporal [95]. Utilizou-se a métrica de análise de performance Relação Sinal - Interferência (*SIR*) [97], gradiente térmico e desvio padrão.

5.3.2 Protótipo da Sonda de Perfilagem

As medidas de temperatura foram efetuadas com o uso de sensores tipo “termistor”. Os termistores são semicondutores que apresentam propriedades físicas específicas, sendo que a sua resistência elétrica diminui com o aumento da temperatura. O tipo de termistor utilizado foi tipo “semente” (*bead*) da Fenwal Electronics. Suas características permitem tempos de resposta na ordem de segundos [10].

Todos os sinais térmicos monitorados foram utilizados na elaboração da tese de doutorado de Alexandrino (2008) [10] no Observatório Nacional, sendo considerados dados bem reais e assim, bem confiáveis.

As sondas térmicas foram fabricadas em latão, no formato cilíndrico, com 200 mm de comprimento e 25 mm de diâmetro. Na parte inferior da sonda localiza-se o compartimento que abriga o termistor. No compartimento central da sonda, encontram-se as ligações elétricas entre o sensor e o cabo de perfilagem com vedação contra infiltração de fluídos do poço. Nas medidas da resistência do termistor utiliza-se um multímetro, conectado ao cabo de perfilagem na Figura 5.8 pode-se verificar o esquema do protótipo da sonda [10].




Figura 5.8 - Esquema do Equipamento de Perfilagem Térmica [10].

5.3.3 Calibração do Equipamento de Perfilagem Térmica

Testes de calibração do equipamento de perfilagem foram efetuados antes e após das principais etapas dos trabalhos de campo. Os termistores não são termômetros absolutos, portanto há necessidade de sua calibração, através da utilização de algum termômetro padrão. No presente caso foi utilizado um termômetro de Platina de alta precisão. A relação entre a resistência (R) do termistor e a temperatura absoluta (T) é geralmente dada sob a forma [10]:

$$R = R_o e^{\left(B\left(\frac{1}{T} - \frac{1}{T_o}\right)\right)} \quad (5.1)$$

onde R_o é a resistência na temperatura T_o e B é a constante característica do material. O coeficiente de temperatura do termistor é, portanto [10],

$$\alpha = \frac{dR}{RdT} = - \frac{B}{T^2}. \quad (5.2)$$

Os testes de calibração desses termistores são efetuados numa certa frequência devido à deriva de suas características elétricas. Nos testes de calibração, utiliza-se uma relação empírica do tipo,

$$\ln(R) = A + \frac{B}{T} + \frac{C}{T^2} \quad (5.3)$$

onde $\ln(R)$ é logaritmo neperiano da resistência (R) do termistor, T a temperatura absoluta em graus Kelvin (K), e A, B e C as constantes características do termistor em Ohms [10].

5.3.4 Gradientes Geotérmicos e Método Convencional (CVL)

Os Gradientes Térmicos foram determinados com base em vários métodos [10]. Nesta análise serão utilizados apenas os Gradientes Térmicos que foram encontrados utilizando o método convencional (CVL) [109].

O método tradicional empregado na determinação de Gradiente Geotérmico é o método convencional (CVL).

A implementação deste método é realizado da seguinte modo, efetua-se a escolha do intervalo de profundidade apropriado para a determinação do gradiente, levando-se em consideração o número de dados de temperatura e informações de perfil litológico do poço. O intervalo de profundidade escolhido para

determinação do gradiente deve estar livre de qualquer processo de perturbação, capaz de afetar o regime geotérmico local [10].

O valor do Gradiente é obtido pelo método de ajuste linear aos dados de profundidade e temperatura, obtidas nas perfilagens térmicas.

Geralmente, o erro percentual na determinação de profundidade é pequeno em relação ao de temperatura [10]. O método dos mínimos quadrados permite estimar os valores dos coeficientes de ajuste linear.

5.3.5 Sinais Analisados

Os dados aplicados no algoritmo proposto são sinais de perfilagem térmica de três cidades brasileiras [10]. São elas, Camaçari – BA, Nova Lima – MG e Jaguarari – BA, respectivamente.




Figura 5.9 - Perfilagem térmica da cidade de Camaçari - BA [10].




Figura 5.10 - Perfilagem térmica da cidade de Nova Lima - MG [10].




Figura 5.11 - Perfilagem térmica da cidade de Jaguarari - BA [10].

5.4 Sinais Teóricos

Nesta seção são demonstrados os sinais aplicados ao algoritmo proposto, gerados teoricamente, utilizando o software Matlab com o objetivo de estabelecer uma relação entre potência de sinal e potência de ruído, e estabelecer uma métrica de erro entre o sinal original e sinal estimado.

5.4.1 Introdução

Para realizar uma análise com parâmetros mais conhecidos e assim, estabelecer variáveis mais determinísticas a fim de obter uma caracterização mais segura do algoritmo proposto foi gerado um sinal teórico para esta finalidade. A esse sinal analisado foi somado níveis diferentes de ruído, porém, com a potência conhecida. A intenção dessa análise é verificar o comportamento do algoritmo proposto variando os níveis de potências do sinal ruído para realizar a comparação dos valores de potência do

sinal estimado pelo algoritmo proposto.

Utilizando o cálculo de potência determinado por Haykin e Moher (2008) [110] como:

$$P = \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} |x(t)|^2 dt = \sum_{n=-\infty}^{\infty} |x(n)|^2. \quad (5.4)$$

Assim, possibilitando verificar a variação das potências do sinal estimado variando a potência de ruído de entrada, com isso, estabelecendo um parâmetro para comprovar teoricamente a eficiência do algoritmo proposto.

O cálculo do erro entre o sinal original teórico e o sinal estimado pelo algoritmo proposto é dado pela diferença entre esses dois sinais.

5.4.2 Sinais Analisados

Foram gerados três tipos de sinais teóricos para realizar os testes do algoritmo proposto. O primeiro sinal foi uma forma de onda senoidal pura, o segundo um sinal modulado usando modulação BPSK⁴⁶ e o último sinal é uma modulação BPSK usando a teoria de múltiplos percursos, considerando não uma mistura instantânea mas, sim, uma mistura convolucional.

O algoritmo usado para realizar a separação cega em todos os sinais teóricos foi a Taxa Máxima Sinal Ruído; sua escolha foi devido ao fato que nas simulações dos sinais práticos ela obteve os melhores resultados.

⁴⁶ Modulação por deslocamento de fase: é um esquema de modulação digital onde a fase da portadora é variada de modo a representar os níveis 0 e 1.

5.4.2.1 Sinal Senoidal Simples

O sinal gerado foi uma forma de onda senoidal usando a função *sin* utilizando o software Matlab. Os sinais ruídos também foram gerados pelo software Matlab usando a função *randn*⁴⁷, as Figuras 5.12 e 5.13 mostram o sinal senoidal e o sinal ruído, respectivamente.

Os sinais gerados possuem dez mil pontos de amostragem. O sinal original e o sinal deslocado foram misturados utilizando uma matriz de mistura aleatória, simulando um sistema real, onde não é conhecida a matriz de mistura, e logo depois foi somado o ruído à mistura.

O sinal analisado foi gerado com uma potência de 10 Watts⁴⁸ e a amplitude do sinal de ruído foi variada analisando assim, a potência do sinal estimado. No Capítulo 6 esses resultados são demonstrados.




Figura 5.12 - Sinal senoidal teórico com potência de 10 Watts.

⁴⁷ Função que gera números pseudo-aleatórios distribuído normalmente.

⁴⁸ É a unidade de potência do Sistema Internacional de Unidades (SI).




Figura 5.13 - Ruído teórico usando a função randn.

5.4.2.2 Sinal Modulado usando BPSK

BPSK (do inglês, *Binary Phase Shift Keying*) é uma técnica de modulação digital que desenvolve um melhor desempenho em termos de taxa de erro de bits [111].

O sinal BPSK pode ser expresso por:

$$s_{BPSK}(t) = A\{\sum_{n=0}^{\infty} x[n]g[(t - nT) + \tau]\} \cos[2\pi(f_c + f_d)t + \phi], \quad (5.5)$$

o sinal da Equação 5.5 pode também ser representado por:

$$s_{BPSK}(t) = A\{\sum_{n=0}^{\infty} x[n]g[(t - nT) + \tau]\} [\cos(2\pi f_d t + \phi) \cos(2\pi f_c t) - \sin(2\pi f_d t + \phi) \sin(2\pi f_c t)], \quad (5.6)$$

onde, A é a amplitude do sinal, T é o período do bit, τ é o atraso de propagação, f_c é a

frequência da portadora, f_d é o desvio de frequência e ϕ é o desvio de fase. O termo $g(t)$ indica o pulso retangular em banda-base⁴⁹. O sinal $x[n]$ representa o símbolo BPSK [111].

O sinal BPSK também pode ser expresso em forma discreta de acordo com a Equação 5.7,

$$s[k] = A \left[\sum_{n=0}^{\infty} x[n] g\left(\frac{k}{f_s} - nT + \tau\right) \right] \left[\cos\left(2\pi \frac{f_d}{f_s} k + \phi\right) \cos\left(2\pi \frac{f_c}{f_s} k\right) - \right. \\ \left. \sin\left(2\pi \frac{f_d}{f_s} k + \phi\right) \sin\left(2\pi \frac{f_c}{f_s} k\right) \right], \quad (5.7)$$

onde f_s é a frequência de amostragem [111].

A Figura 5.14 mostra uma parte do sinal digital que foi modulado para simulação.




Figura 5.14 - Sinal digital usado na modulação BPSK.

⁴⁹ É um sinal que tem uma gama de frequências muito estreitas.

A Figura 5.15 mostra o sinal da portadora usada na modulação do sinal digital.




Figura 5.15 - Sinal da portadora usado na modulação do sinal digital.

A Figura 5.16 demonstra o sinal modulado BPSK utilizando os sinais mostrados nas Figuras 5.14 e 5.15.




Figura 5.16 - Sinal modulado usando BPSK.

5.4.2.3 Sinal Modulado usando BPSK para Múltiplos Percursos

O sinal modulado BPSK aplicado nesta seção é gerado da mesma forma que o sinal BPSK da seção 5.4.2.2, a diferença é que a mistura foi realizada de maneira diferente, considerando múltiplos percursos.

5.4.2.3.1 Múltiplos Percursos

Ao utilizar um modelo de propagação por múltiplos percursos são introduzidos importantes distorções no sinal transmitido de forma a comprometer o desempenho do sistema devido à elevação da taxa de erro de bit [112].

Normalmente, a propagação por múltiplos percursos em um radioenlace digital acontece quando há a formação de dutos atmosféricos. Em nosso caso, em monitoramento, isso acontece quando os sinais são captados por sensores com atrasos temporais, monitorando assim sinais e ruídos atrasados no tempo [112].

A caracterização da propagação por múltiplos percursos citada anteriormente (enlace digital) é o modelo clássico de análise. No caso específico desse trabalho, considerando sinais monitorados por sensores, os múltiplos percursos podem ocorrer devido ao retorno de sinais. Esse fenômeno ocorre devido à alguns fatores, por exemplo, a descalibração do equipamento de medição, à não equivalência de impedâncias do cabo e do equipamento de medição.

O efeito de múltiplos percursos neste trabalho foi considerado com intenção de verificar a robustez e a eficiência do algoritmo proposto. Os resultados obtidos foram os esperados, uma vez que os algoritmos usados na aplicação da BSS eram somente para misturas instantâneas.

5.5 Considerações Finais deste Capítulo

Este capítulo apresentou os sinais que foram analisados pelo algoritmo proposto. Foram utilizados quatro tipos diferentes de sinais, começando com sinais adquiridos através de ensaios práticos utilizando extensômetros resistivos realizados na Escola de Minas na Universidade Federal de Ouro Preto, mais precisamente no laboratório de Estruturas. Depois aplicou-se ao algoritmo proposto sinais gerados através da pesquisa de Nunes (2012) [11] que se trata de dois tipos de sinais, um experimental e outro numérico. O terceiro tipo de sinais se trata de caracterização de perfilagem térmica realizada por Alexandrino (2008) [10] de vários poços em algumas cidades dos Estados de Minas Gerais e Bahia. Por último, sinais gerados teoricamente para ter simulações do algoritmo proposto de forma mais segura e conhecida.

CAPÍTULO 6

RESULTADOS OBTIDOS

Neste capítulo serão apresentados todos os resultados das análises realizadas, verificando a experiência prática com extensômetros, o modelo experimental e numérico, a experiência prática com sondas térmicas e os sinais teóricos gerados.

6.1 Resultados do Ensaio Prático com Extensômetros

A Figura 6.1 mostra o ruído detectado no ensaio 1, correspondente a Tabela 5.1. Considera-se ruído (Figura 6.1) qualquer componente de sinal que não seja da fonte desejada, ou seja, componentes de fontes indesejadas e fontes ruidosas. Estes dados foram adquiridos a partir da aplicação da técnica Relação Máxima Sinal Ruído [96].




Figura 6.1 - Ruído detectado pelo algoritmo proposto do ensaio 1 da Tabela 5.1.

A Figura 6.2 mostra os sinais de entradas e seus sinais estimados do ensaio 1(um), no extensômetro 1 (cabo curto-enrolado) e extensômetro 2 (cabo curto-retíneo) utilizando a técnica de Relação Máxima Sinal Ruído.

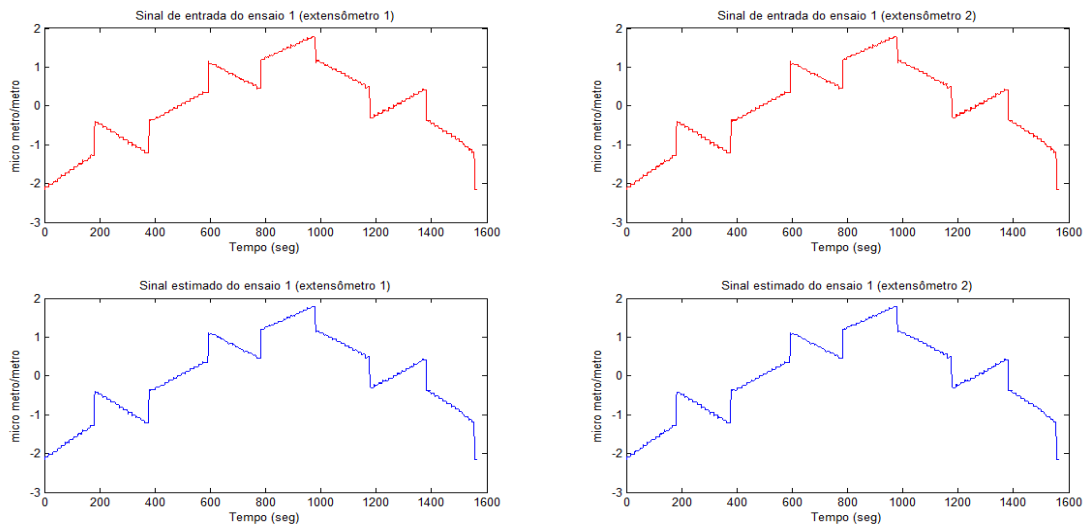


Figura 6.2 - Sinais de entradas e estimados do ensaio 1(um) usando a técnica de relação máxima sinal ruído.

A Tabela 6.1 mostra a configuração dos ensaios, nível de ruído teórico e relação sinal ruído (SNR) usando a técnica Relação Máxima Sinal Ruído. Isto serve para comprovar o funcionamento adequado do algoritmo proposto.

Tabela 6.1 - Relação da configuração dos ensaios, nível teórico de ruído e SNR usando a Relação Máxima Sinal Ruído.

Número do Ensaio	Entrada do Equipamento	Comprimento do Cabo		Disposição do Cabo		Nível de Ruído Teórico	SNR
		Curto	Longo	Retilíneo	Enrolado		
Ensaio 1	Extensômetro 1	X			X	Maior	11,72
	Extensômetro 2	X		X		Menor	11,75
Ensaio 2	Extensômetro 1	X			X	Menor	11,26
	Extensômetro 2		X		X	Maior	11,21
Ensaio 3	Extensômetro 1	X		X		Menor	11,44
	Extensômetro 2		X		X	Maior	11,43
Ensaio 4	Extensômetro 1	X		X		Menor	10,85
	Extensômetro 2		X	X		Maior	10,72
Ensaio 5	Extensômetro 1		X		X ⁴¹	Maior	10,70
	Extensômetro 2	X		X		Menor	10,74
Ensaio 6	Extensômetro 1		X	X		Menor	11,15
	Extensômetro 2		X		X	Maior	11,06

Constatando realmente, que o algoritmo proposto é capaz de identificar níveis de ruído na análise dos sinais, e que a sua caracterização está de acordo com os níveis teóricos indicados.

A Tabela 6.2 mostra as porcentagens das convergências dos sinais, calculando esse índice entre sinais experimentais, depois entre os sinais apresentados pelo algoritmo proposto. A convergência entre esses últimos é bem maior, ou seja, diminuindo a distância entre os sinais.

Tabela 6.2 - Porcentagens de convergências entre sinais experimentais e entre sinais apresentados pelo algoritmo proposto.

Número do Ensaio	Convergência dos Sinais (%)	
	Sinais Experimentais	Sinais Algoritmo Proposto
Ensaio 1	17	83
Ensaio 2	18	82
Ensaio 3	18	82
Ensaio 4	16	84
Ensaio 5	14	86
Ensaio 6	9	91

A Tabela 6.3 identifica os valores das métricas de performance (Relação Sinal Ruído, Relação Sinal Distorção e Relação Sinal Interferência) determinados para algoritmos Relação Máxima Sinal Ruído e Previsibilidade Temporal.

Tabela 6.3 - Resultado dos valores das métricas de performance utilizando o algoritmo relação máxima sinal ruído e previsibilidade temporal.

Número do Ensaio	Extensômetro	Relação Máxima Sinal - Ruído			Previsibilidade Temporal		
		SNR	SDR	SIRI	SNR	SDR	SIRI
Ensaio 1	Ext. 1	11,72	11,70	2,13	11,68	11,64	2,09
	Ext. 2	11,75	11,71	2,17	11,69	11,66	2,11
Ensaio 2	Ext. 1	11,26	11,20	2,08	11,20	11,18	2,07
	Ext. 2	11,21	11,19	2,06	11,18	11,15	2,04
Ensaio 3	Ext. 1	11,44	11,41	2,14	11,37	11,29	2,12
	Ext. 2	11,43	11,39	2,13	11,34	11,27	2,09
Ensaio 4	Ext. 1	10,85	10,81	2,06	10,80	10,78	2,05
	Ext. 2	10,72	10,65	2,02	10,69	10,63	2,00
Ensaio 5	Ext. 1	10,70	10,67	2,14	10,68	10,63	2,10
	Ext. 2	10,74	10,68	2,16	10,70	10,65	2,13
Ensaio 6	Ext. 1	11,15	11,06	2,15	11,08	11,00	2,10
	Ext. 2	11,06	11,02	2,13	11,04	10,98	2,08

Ao analisar a Tabela 6.3 é possível constatar que o algoritmo Relação Máxima Sinal Ruído foi mais eficiente na análise dos sinais analisados nos seis ensaios práticos.

6.2 Resultados do Modelo Experimental e Numérico

Essa análise é feita comparando as medidas de performance entre o sinal experimental e seu modelo numérico [11], e também, entre o sinal determinado pelo algoritmo proposto e o modelo numérico. A Tabela 6.4 descreve as porcentagens de convergências entre os sinais.

Tabela 6.4 - Convergência entre sinais experimental, numérico e BSS usando a relação máxima sinal ruído.

Convergência dos Sinais (%)	
Experimental e Numérico	Algoritmo Proposto e Numérico
11	89

A Tabela 6.5 demonstra os valores para a medida de performance SIR (relação sinal interferência), dos sinais analisados (experimental, numérico e algoritmo proposto) para os algoritmos Relação Máxima Sinal Ruído e Previsibilidade Temporal.

Tabela 6.5 - Valores da medida de performance para os dados experimental, numérico e algoritmo proposto.

Tipo do sinal	Relação Máxima Sinal Ruído	Previsibilidade Temporal
	SIRI	SIRI
Algoritmo Proposto / Experimental	2,99	2,87
Algoritmo Proposto / Numérico	3,81	3,70

6.3 Resultados do Ensaio Prático com Sondas Térmicas

Essa análise é feita comparando a medida de performance SIR (Relação Sinal Interferência) relacionando os sinais práticos com os sinais do algoritmo proposto. Nestes ensaios, em específico, as medidas de análises mais importantes, de acordo com as teorias de geofísica [10], são os gradientes térmicos e seus respectivos, desvios padrões.

As Figuras 6.3, 6.4 e 6.5 mostram os sinais estimados pelo algoritmo proposto usando o algoritmo Relação Máxima Sinal Ruído para as cidades de Camaçari – BA, Nova Lima – MG e Jaguarari – BA, respectivamente.




Figura 6.3 - Perfilagem térmica estimada pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Camaçari - BA.




Figura 6.4 - Perfilagem térmica estima pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Nova Lima - MG.




Figura 6.5 - Perfilagem térmica estimada pelo algoritmo proposto usando relação máxima sinal ruído da cidade de Jaguarari - BA.

Os gradientes térmicos originais e seus respectivos desvios padrões

determinados a partir da perfilagem térmica dos poços estão representados na Tabela 6.6 [10].

Tabela 6.6 - Valores dos Gradientes Térmicos e Desvios Padrões das Perfilagens Térmicas Originais [10].

Gradientes Térmicos e Desvios Padrões dos Poços (Originais)		
Cidade	Gradiente Térmico (°C/Km)	Desvio Padrão (°C/Km)
Jaguarari	10,056	0,039
Camaçari	23,210	0,760
Nova Lima	15,371	1,283

A Tabela 6.7 mostra os valores dos gradientes térmicos, bem como seus respectivos desvios padrões, após os sinais das perfilagens térmicas originais serem tratados pelo algoritmo proposto.

Tabela 6.7 - Valores dos gradientes térmicos e desvios padrões das perfilagens térmicas após tratamento pelo algoritmo proposto.

Gradientes Térmicos e Desvios Padrões dos Poços (Algoritmo Proposto)		
Cidade	Gradiente Térmico (°C/Km)	Desvio Padrão (°C/Km)
Jaguarari	10,818	0,034
Camaçari	24,340	0,780
Nova Lima	15,692	1,086

A Tabela 6.8 demonstra os resultados entre a Tabela 6.6 e a Tabela 6.7, comparando os valores dos gradientes térmicos e os desvios padrões, obtendo uma relação de porcentagem, determinando se houve aumento ou diminuição dos parâmetros em relação aos sinais de perfilagem térmica do algoritmo proposto e originais.

Tabela 6.8 - Porcentagem entre gradientes térmicos e desvios padrões (algoritmo proposto e originais).

Porcentagem entre Gradientes Térmicos e Desvios Padrões dos Poços (Algoritmo Proposto – Originais [10])				
Cidade	Gradiente Térmico (%)		Desvio Padrão (%)	
Jaguarari	7,58	↑	12,82	↓
Camaçari	4,87	↑	1,52	↑
Nova Lima	2,10	↑	15,35	↓
Média	4,85	↑	8,88	↓

A métrica de performance, relação sinal interferência (SIR) [97] foi aplicada nos sinais de perfilagem térmica originais [10] e nos sinais determinados pelo algoritmo proposto. É possível verificar pela Tabela 6.9 que o algoritmo proposto apresenta uma SIR maior que os sinais originais.

Tabela 6.9 - Valores da métrica SIR entre as perfilagens térmicas do algoritmo proposto e originais.

Métrica SIR de Performance (dB)	
Cidade	SIR
Jaguarari	4,425
Camaçari	4,265
Nova Lima	3,978
Média	4,223

6.4 Resultados dos Sinais Teóricos

Como citado no capítulo 5, foram gerados sinais teóricos (sinais senoidais, modulados e ruídos aleatórios) como sinais a serem analisados pelo algoritmo proposto. A ideia principal é analisar a variação da potência do sinal estimado comparado com a potência do sinal original quando há variação da potência do sinal de ruído, e monitorando o erro entre os sinais.

6.4.1 Sinal Senoidal Simples

Nesta análise o sinal senoidal simples foi deslocado no tempo, depois os sinais foram misturados (sinal original e sinal deslocado) e o ruído somado à mistura. A Figura 6.6 mostra o diagrama de blocos desta operação.

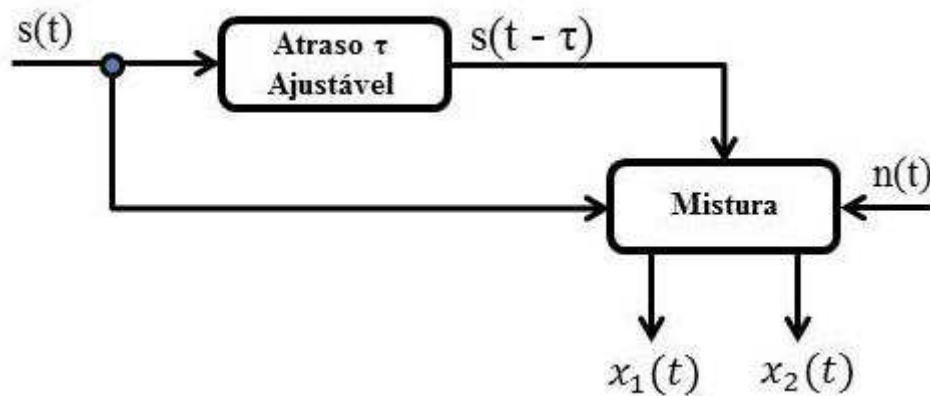


Figura 6.6 - Fluxograma de mistura dos sinais original, deslocado e ruído.

A Figura 6.7 descreve o sinal senoidal utilizado como sinal de entrada no algoritmo proposto, possuindo 10 Watts de potência de acordo com a Equação 5.6.




Figura 6.7 - Sinal senoidal teórico com potência de 10 Watts.

A Figura 6.8 descreve o ruído inicial somado ao sinal de entrada analisado pelo algoritmo proposto, este sinal possui uma potência, segundo a Equação 5.6, de 0,0983 Watt.




Figura 6.8 - Ruído gerado aleatoriamente com potência de 0,0983 Watt.

As Figuras 6.9 e 6.10 mostram os sinais misturados (sinal original, sinal deslocado e sinal ruído com potência de 0,0983 Watt).




Figura 6.9 - Sinal misturado 1 com potência de ruído igual 0.0983 Watt.




Figura 6.10 - Sinal misturado 2 com potência de ruído igual 0.0983 Watt.

Na Figura 6.11 pode-se visualizar o sinal estimado para a potência de ruído de 0.0983 Watt.




Figura 6.11 - Sinal estimado para uma potência de ruído de 0,0983 Watt.

A Tabela 6.10 mostra o desenvolvimento da relação de potência de sinal de entrada com potência de sinal estimado quando a potência de ruído é variada.

Tabela 6.10 - Relação potência de ruído x potência do sinal estimado dos sinais teóricos.

Simulação	Potência do Ruído (Watts)	Potência do Sinal Original (Watts)	Potência do Sinal Estimado (Watts)	Erro Médio (10^{-11})
1	0,0983	10,0000000000000011	10,0000000000000089	1,5789
2	0,3916	10,0000000000000011	9,999999999999783	1,5789
3	0,8846	10,0000000000000011	10,0000000000000096	1,5791
4	1,5727	10,0000000000000011	10,0000000000000076	1,5790
5	2,4575	10,0000000000000011	10,0000000000000112	1,5793
6	3,5387	10,0000000000000011	10,0000000000000076	1,5795
7	4,8166	10,0000000000000011	10,0000000000000087	1,5790
8	6,2911	10,0000000000000011	10,0000000000000137	1,5797
9	7,9622	10,0000000000000011	10,0000000000000080	1,5802
10	9,8298	10,0000000000000011	10,0000000000000124	1,5811
11	11,8941	10,0000000000000011	10,0000000000000103	1,5820
12	14,1550	10,0000000000000011	10,0000000000000080	1,5946
13	16,6124	10,0000000000000011	10,0000000000000137	1,6045
14	19,2665	10,0000000000000011	10,0000000000001627	1,6589
15	22,1171	10,0000000000000011	10,000000000000163	1,6788

Ao analisar a Tabela 6.10 é possível constatar que o erro tem pouca variação em relação ao aumento da potência de ruído. Como o erro é muito pequeno a potência do sinal estimado também varia muito pouco em relação à potência do sinal original. Na Figura 6.12 é possível observar, exatamente, como se dá essa relação potência de ruído por erro.




Figura 6.12 - Relação potência de ruído por erro médio do sinal senoidal simples.

As Figuras 6.13, 6.14 e 6.15 demonstram o sinal estimado, o sinal de ruído e a diferença entre o sinal original e sinal estimado na simulação de número 10, correspondendo a potência de ruído igual 9,8298 Watts (praticamente a mesma potência do sinal de entrada).




Figura 6.13 - Sinal estimado para uma potência de ruído de 9,8298 Watts.




Figura 6.14 - Sinal ruído com potência de 9,8298 Watts.




Figura 6.15 - Diferença entre sinal original e sinal estimado para potência de ruído de 9,8298 Watts.

As Figuras 6.16, 6.17 e 6.18 demonstram o sinal estimado, o sinal de ruído e a

diferença entre o sinal original e sinal estimado na simulação de número 15, correspondendo a potência de ruído igual 22,1171 Watts (praticamente o dobro da potência do sinal de entrada).




Figura 6.16 - Sinal estimado para uma potência de ruído de 22,1171 Watts.




Figura 6.17 - Sinal ruído com potência de 22,1171 Watts.




Figura 6.18 - Diferença entre sinal original e sinal estimado para potência de ruído de 22,1171 Watts.

Verificou-se que o algoritmo proposto mantém praticamente o mesmo nível de potência de saída para diferentes potências de ruído na entrada, bem como manteve praticamente constante o nível de erro no sinal estimado.

6.4.2 Sinal Modulado usando BPSK

A Tabela 6.11 mostra os resultados obtidos nas simulações em sinais modulados usando BPSK.

Tabela 6.11 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado.

Simulação	Potência Sinal	Potência Ruído	Potência Sinal Estimado	Erro Médio (10^{-9})
1	50,000000000000007	0,1040	50,006206649903305	3,5611
2	50,000000000000007	0,3995	50,000047096804316	3,5641
3	50,000000000000007	0,8988	50,000841667336985	3,5723
4	50,000000000000007	1,5979	50,000721452545820	3,5748
5	50,000000000000007	2,4967	50,000015425878550	3,5754
6	50,000000000000007	3,5952	50,000625487258245	3,5780
7	50,000000000000007	4,8935	50,000325412489654	3,5808
8	50,000000000000007	6,3915	50,001265487828254	3,5836
9	50,000000000000007	8,0893	50,000325154785425	3,5860
10	50,000000000000007	9,9867	50,000325487524525	3,5882
11	50,000000000000007	12,0839	50,000548782156987	3,5901
12	50,000000000000007	14,3809	50,000879853585452	3,5918
13	50,000000000000007	16,8776	50,000147859875358	3,5933
14	50,000000000000007	19,5740	50,000369875685488	3,5947
15	50,000000000000007	22,4701	50,002145845236987	3,5959
16	50,000000000000007	25,5660	50,000321548524788	3,5970
17	50,000000000000007	28,8617	50,000326587895487	3,5980
18	50,000000000000007	32,3570	50,000325453698785	3,5988
19	50,000000000000007	36,0521	50,000124578545985	3,5996
20	50,000000000000007	39,9469	50,003512147858785	3,6004
21	50,000000000000007	44,0415	50,000325487895878	3,6011
22	50,000000000000007	48,3358	50,000987512358987	3,6017
23	50,000000000000007	52,8298	50,000032587745895	3,6023
24	50,000000000000007	57,5236	50,002321458784587	3,6028
25	50,000000000000007	62,4171	50,000122248759858	3,6033
26	50,000000000000007	67,5103	50,000336545258789	3,6037
27	50,000000000000007	72,8033	50,000222145247898	3,6042
28	50,000000000000007	78,2960	50,000333658745985	3,6046
29	50,000000000000007	83,9884	50,000555487828788	3,6049
30	50,000000000000007	89,8806	50,000122144745987	3,6053
31	50,000000000000007	95,9725	50,000022123254987	3,6056
32	50,000000000000007	102,2641	50,000111478249858	3,6059

Ao analisar a Tabela 6.11 é possível constatar que o erro, também, tem pouca variação em relação ao aumento da potência de ruído, assim como na análise do sinal senoidal simples. Porém, o sinal modulado usando BPSK apresentou um erro maior que o sinal anterior, em decorrência disso, a potência do sinal estimado indicou uma maior variação. A Figura 6.19 mostra exatamente como se dá essa relação potência de ruído por erro para o sinal modulado usando BPSK.




Figura 6.19 - Relação potência de ruído por erro médio do sinal modulado usando BPSK.

As Figuras 6.20 - 6.23 mostram os sinais modulados (sinal original e deslocado) misturados, o ruído e o sinal modulado estimado para uma potência de 0.1040 Watt (simulação 1 – Tabela 6.11).




Figura 6.20 - Sinal modulado normalizado misturado 1 com potência de ruído de 0.104 Watt.




Figura 6.21 - Sinal modulado normalizado misturado 2 com potência de ruído de 0.104 Watt.




Figura 6.22 - Sinal ruído com potência de 0.104 Watt.




Figura 6.23 - Sinal modulado estimado com potência de ruído de 0.104 Watt.

As Figuras 6.24 - 6.27 mostram os sinais modulados (sinal original e deslocado) misturados, o ruído e o sinal modulado estimado para uma potência de 102,2641 Watts

(simulação 32 – Tabela 6.11).




Figura 6.24 - Sinal modulado normalizado misturado 1 com potência de ruído de 102.2641 Watts.




Figura 6.25 - Sinal modulado normalizado misturado 2 com potência de ruído de 102.2641 Watts.




Figura 6.26 - Sinal ruído com potência de 102.2641 Watts.




Figura 6.27 - Sinal modulado estimado com potência de ruído de 102.2641 Watts.

6.4.3 Sinal Modulado usando BPSK para Múltiplos Percursos

Como citado na seção 5.4.2.3 o sinal teórico (sinal modulado usando BPSK) foi gerado da mesma forma que os sinais da seção 5.4.2.2. Porém, aqui nesta seção, as

formas de misturas dos sinais foram tratadas de maneira diferente, ou seja, considerando múltiplos percursos.

Múltiplos percursos acarretam vários atrasos temporais do sinal original no sensor de recepção, com isso, os sinais monitorados não devem ser considerados misturas instantâneas, mas sim, misturas convolutivas.

6.4.3.1 Múltiplos Percursos - Mistura 1

Nesta análise o sinal original modulado foi deslocado no tempo, depois deslocou-se o ruído no tempo, e depois foram somados (sinal original com ruído e sinal deslocado com ruído deslocado) e só após isso, os sinais foram misturados. A Figura 6.28 mostra o diagrama de blocos desta operação. Assim, aumentando muito a complexidade de separação desses sinais, aumentando assim, consideravelmente o poder necessário do algoritmo para realizar a separação cega dos sinais.

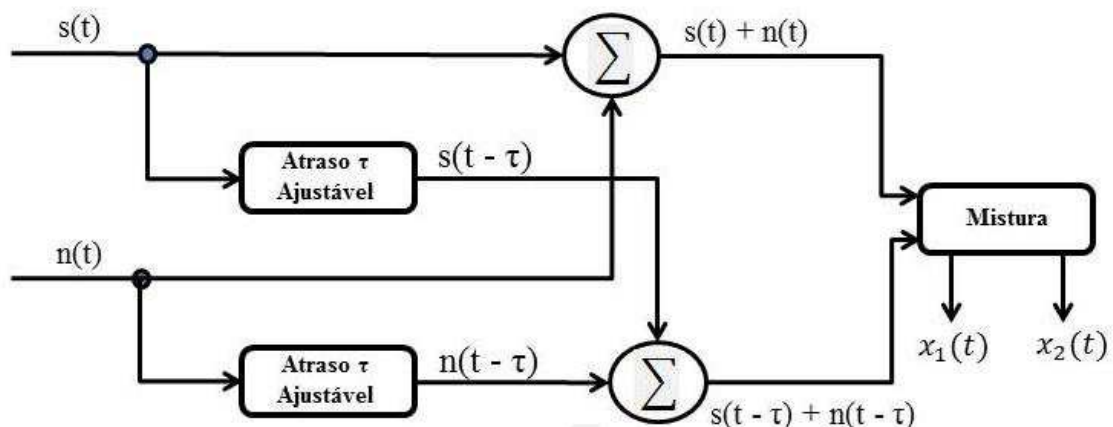


Figura 6.28 - Fluxograma do sistema de mistura 1 para múltiplos percursos.

A Tabela 6.12 mostra os resultados obtidos usando esse tipo de sinal usando a mistura 1 para múltiplos percursos através do algoritmo proposto.

Tabela 6.12 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 1 para múltiplos percursos.

Simulação	Potência Sinal	Potência Ruído	Potência Sinal Estimado	Erro Médio
1	50,000000000000007	0,0998	50,008256100625339	1,478898187583407
2	50,000000000000007	0,3995	50,027941887469098	2,462239227061097
3	50,000000000000007	0,8988	50,050615158462499	3,311031296353243
4	50,000000000000007	1,5979	50,071195712954271	3,985190080260307
5	50,000000000000007	2,4967	50,088066899421634	4,508211573857334
6	50,000000000000007	3,5952	50,101342794094627	4,917005839710297
7	50,000000000000007	4,8935	50,111669509664651	5,242098792472334
8	50,000000000000007	6,3915	50,119722419422885	5,505032400972737
9	50,000000000000007	8,0893	50,126058835281562	5,721562734597768
10	50,000000000000007	9,9867	50,131102989669017	5,902846706894940
11	50,000000000000007	12,0839	50,135168503529108	6,056067466181617
12	50,000000000000007	14,3808	50,138485537153990	6,187003464796193
13	50,000000000000007	16,5481	50,141223510465053	6,299699658726650
14	50,000000000000007	19,5740	50,143508134092329	6,397831682524498
15	50,000000000000007	22,4701	50,145433652622607	6,484114875188214
16	50,000000000000007	25,5660	50,147071517673226	6,560252434127723
17	50,000000000000007	28,8617	50,148476519982310	6,627906685700796
18	50,000000000000007	32,3570	50,149691144572110	6,688246758232894
19	50,000000000000007	36,0521	50,150748688256868	6,742359478602293
20	50,000000000000007	39,9469	50,151675512534958	6,791470272643577
21	50,000000000000007	44,0415	50,152492688426797	6,836341178346566
22	50,000000000000007	48,3358	50,153217209978287	6,877329770447833
23	50,000000000000007	52,8298	50,153862898842227	6,914986522063560
24	50,000000000000007	57,5236	50,154441085393209	6,949584698918676
25	50,000000000000007	62,4171	50,154961126562235	6,981520858373730
26	50,000000000000007	67,5103	50,155430803191294	7,011121891843335
27	50,000000000000007	72,8033	50,155856627630797	7,038632033972180
28	50,000000000000007	78,2960	50,156244083854425	7,064189444296409
29	50,000000000000007	83,9884	50,156597816383602	7,088032514548945
30	50,000000000000007	89,8806	50,156921780056898	7,110333218548096
31	50,000000000000007	95,9725	50,157219359604952	7,131176622333099
32	50,000000000000007	102,2641	50,157492465763466	7,150698441703058

As Figuras 6.29 - 6.31 mostram o sinal modulado original, o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 0.0998 Watt de acordo com a Tabela 6.12.




Figura 6.29 - Sinal modulado original com potência de 50 Watts.




Figura 6.30 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 0.0998 Watt.




Figura 6.31 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 0.0998 Watt.

A Figura 6.32 mostra o sinal modulado estimado considerando o sistema de mistura 1 para múltiplos percursos.




Figura 6.32 - Sinal modulado estimado considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 0.0998 Watt.

A Figura 6.33 mostra o erro remanescente entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt.




Figura 6.33 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt considerando sistema de mistura 1 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.12 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original. Porém, o erro médio é grande como pode ser visualizado através da Figura 6.33, e isso para um nível de potência de ruído baixo, 0.0998 Watt.

As Figuras 6.34 e 6.35 mostram o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 102,2641 Watts de acordo com a Tabela 6.12.




Figura 6.34 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2641 Watts.




Figura 6.35 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2641 Watts.

A Figura 6.36 mostra o sinal modulado estimado considerando o sistema de mistura 1 para múltiplos percursos para potência de ruído de 102.2641 Watts.




Figura 6.36 - Sinal modulado estimado considerando sistema de mistura 1 para múltiplos percursos com potência de ruído de 102.2146 Watts.

A Figura 6.37 mostra o erro remanescente entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 120.2146 Watts.




Figura 6.37 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102.2146 Watts considerando sistema de mistura 1 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.12 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original como para potências de ruídos mais baixas. Porém, o erro médio aumenta à medida que a potência de ruído cresce. A Figura 6.37 mostra o erro remanescente entre o sinal modulado estimado e o sinal modulado original.

A Tabela 6.13 mostra os erros médios dos sinais quando aplicado deslocamentos temporais diferentes utilizando o sistema de mistura 1 em comparação aos valores dos erros médios da Tabela 6.12 utilizando deslocamento unitário e potência de ruído de 0,0998 Watt.

Tabela 6.13 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 1.

Deslocamento Temporal Variável		
Deslocamento Temporal	Potência do Sinal Estimado	Erro Médio
1	50,008256100625339	1,478898187583407
5	50,009556417834595	4,526073837289381
10	50,014550696584543	5,445068332675668
15	50,024114248344567	6,080190859801436
20	50,019729814915088	6,166838387573501
25	50,010517444672352	5,200813811967529
30	50,005583974312351	12,136650564928129
50	50,007891695702170	12,490888469401554
100	50,005575947205948	1,944779716903623

Na Tabela 6.13 é possível verificar que mesmo aumentando o deslocamento temporal pode ocorrer a diminuição do erro médio, visto que os algoritmos cegos aplicados neste trabalho não são os ideais para misturas convolucionais.

6.4.3.2 Múltiplos Percursos - Mistura 2

Nesta análise o ruído foi somado ao sinal original modulado, depois deslocou-se o resultado no tempo, e depois foram misturados (sinal original com ruído e sinal original com ruído deslocados). A Figura 6.38 mostra o diagrama de blocos desta operação. Assim, alterado a complexidade necessária para realizar a separação desses sinais, em relação a complexidade da seção 6.4.3.1.

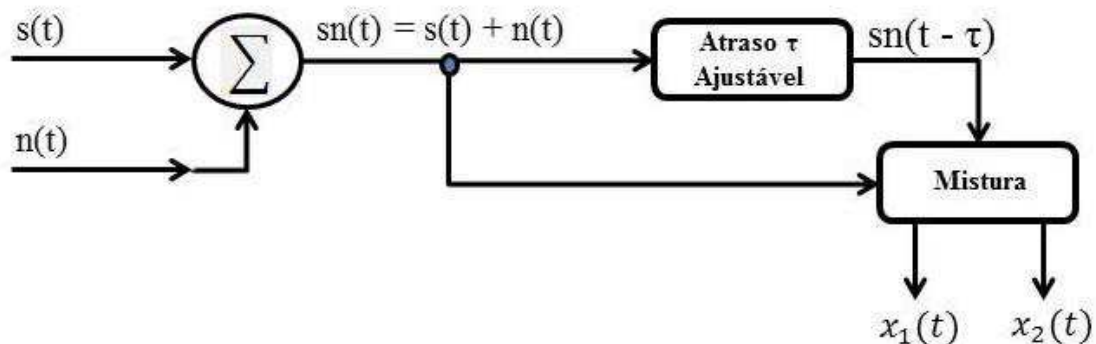


Figura 6.38 - Fluxograma do sistema de mistura 2 para múltiplos percursos.

A Tabela 6.14 mostra os resultados obtidos usando o sinal modulado BPSK considerando a mistura 2 para múltiplos percursos através do algoritmo proposto.

Tabela 6.14 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 2 para múltiplos percursos.

Simulação	Potência Sinal	Potência Ruído	Potência Sinal Estimado	Erro Médio
1	50,000000000000007	0,0998	50,008243730314781	1,478901300187827
2	50,000000000000007	0,3995	50,027923339654052	2,462256171122543
3	50,000000000000007	0,8988	50,050593430606135	3,311054181913042
4	50,000000000000007	1,5979	50,071173083443057	3,985215220763698
5	50,000000000000007	2,4967	50,088044648195527	4,508236512749685
6	50,000000000000007	3,5952	50,101321530750035	4,917029370643477
7	50,000000000000007	4,8935	50,111649469741849	5,242121484521992
8	50,000000000000007	6,3915	50,119703647855957	5,505053136864109
9	50,000000000000007	8,0893	50,126041286715022	5,721582419661072
10	50,000000000000007	9,9867	50,131086580395234	5,902865428171274
11	50,000000000000007	12,0839	50,135153137486185	6,056085229727128
12	50,000000000000007	14,3808	50,138471118459897	6,187019888988016
13	50,000000000000007	16,5481	50,141209949072788	6,299714927532923
14	50,000000000000007	19,5740	50,143495347971431	6,397845965148421
15	50,000000000000007	22,4701	50,145421568229601	6,484128634507265
16	50,000000000000007	25,5660	50,147060069612344	6,560265504944415
17	50,000000000000007	28,8617	50,148465650321782	6,627918946091937
18	50,000000000000007	32,3570	50,149680802050248	6,688258382804641
19	50,000000000000007	36,0521	50,150738827491054	6,742370431969131
20	50,000000000000007	39,9469	50,151666093287318	6,791481066804048
21	50,000000000000007	44,0415	50,152483674944939	6,836351704015838
22	50,000000000000007	48,3358	50,153208570416218	6,877339781479095
23	50,000000000000007	52,8298	50,153854604756901	6,914996201435594
24	50,000000000000007	57,5236	50,154433111309146	6,949594006089036
25	50,000000000000007	62,4171	50,154953449598089	6,981529875061014
26	50,000000000000007	67,5103	50,155423402736631	7,011130564461604
27	50,000000000000007	72,8033	50,155849485070007	7,038640331402707
28	50,000000000000007	78,2960	50,156237182327523	7,064197420443080
29	50,000000000000007	83,9884	50,156591140581170	7,088040122526566
30	50,000000000000007	89,8806	50,156915316041733	7,110340533591325
31	50,000000000000007	95,9725	50,157213094657941	7,131183682224075
32	50,000000000000007	102,2641	50,157487388250033	7,150705263046951

Nas Figuras 6.39 - 6.41 é possível verificar o sinal modulado original, o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 0.0998 Watt de acordo com a Tabela 6.14.




Figura 6.39 - Sinal modulado original com potência de 50 Watts.




Figura 6.40 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0998 Watt.




Figura 6.41 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0998 Watt.

Na Figura 6.42 é possível verificar o sinal modulado estimado considerando o sistema de mistura 2 para múltiplos percursos.




Figura 6.42 - Sinal modulado estimado considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 0.0998 Watt.

Na Figura 6.43 é possível verificar o erro remanescente entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0,0999 Watt.




Figura 6.43 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0999 Watt considerando sistema de mistura 2 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.14 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original. Porém, o erro médio é grande como pode ser visualizado através da Figura 6.43, e isso para um nível de potência de ruído baixo, 0,0998 Watt.

As Figuras 6.44 e 6.45 mostram o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 102,2641 Watts de acordo com a Tabela 6.14.




Figura 6.44 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2641 Watts.




Figura 6.45 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2641 Watts.

Na Figura 6.46 é possível visualizar o sinal modulado estimado considerando o sistema de mistura 2 para múltiplos percursos para potência de ruído de 102.2641 Watts.




Figura 6.46 - Sinal modulado estimado considerando sistema de mistura 2 para múltiplos percursos com potência de ruído de 102.2146 Watts.

Na Figura 6.47 é possível visualizar o erro remanescente entre o sinal modulado original e o sinal modulado estimado para o sistema de mistura 2 com potência de ruído de 120.2146 Watts.




Figura 6.47 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102.2146 Watts considerando sistema de mistura 2 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.14 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original como para potências de ruídos mais baixas. Porém, o erro médio também aumenta à medida que a potência de ruído cresce, como na Tabela 6.12.

A Tabela 6.15 mostra os erros médios dos sinais quando aplicados deslocamentos temporais diferentes utilizando o sistema de mistura 2 em comparação aos valores dos erros médios da Tabela 6.14 utilizando deslocamento unitário e a potência de ruído usada foi sempre a mesma, 0,0998 Watt.

Tabela 6.15 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 2.

Deslocamento Temporal Variável		
Deslocamento Temporal	Potência do Sinal Estimado	Erro Médio
1	50,008243730314781	1,478901300187827
5	50,009998704644502	4,528166375599299
10	50,020100402331245	5,452596278862543
15	50,057140558869527	6,0867070777811751
20	50,093855477420014	6,172699361190385
25	50,090495233307145	5,209411739116458
30	50,002765083444416	12,120758876753424
50	50,002579446575474	12,490979063652276
100	50,055062896289826	1,943566834554589

A Tabela 6.15 mostra que mesmo aumentando o deslocamento temporal pode ocorrer a diminuição do erro médio, visto que os algoritmos cegos aplicados neste trabalho não são os ideais para misturas convolucionais, assim como apresentado na Tabela 6.13.

6.4.3.3 Múltiplos Percursos - Mistura 3

Nesta análise deslocou-se o sinal modulado original no tempo, depois o ruído foi somado aos sinais original e deslocado, depois os dois sinais foram novamente deslocados no tempo, e para finalizar os sinais resultantes foram misturados. A Figura 6.48 mostra o diagrama de blocos desta operação. Assim, alterado a complexidade necessária para realizar a separação desses sinais, em relação à complexidade das seções 6.4.3.1 e 6.4.3.2.

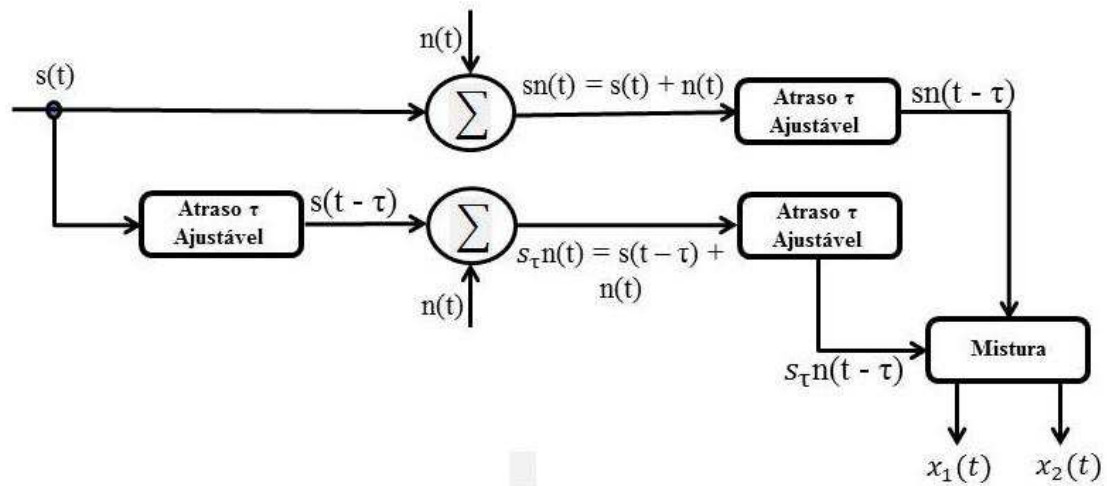


Figura 6.48 - Fluxograma do sistema de mistura 3 para múltiplos percursos.

A Tabela 6.16 mostra os resultados obtidos usando o sinal modulado BPSK considerando a mistura 3 para múltiplos percursos através do algoritmo proposto.

Tabela 6.16 - Potência do sinal, do ruído, do sinal estimado e erro médio do sinal modulado considerando sistema de mistura 3 para múltiplos percursos.

Simulação	Potência Sinal	Potência Ruído	Potência Sinal Estimado	Erro Médio
1	50,000000000000007	0,0998	50,007393487220995	2,020308463842045
2	50,000000000000007	0,3995	50,023613022245513	3,377609212812897
3	50,000000000000007	0,8988	50,038931157372048	4,312990698726933
4	50,000000000000007	1,5979	50,050527907029355	4,963932475436957
5	50,000000000000007	2,4967	50,058760450249785	5,426833648902292
6	50,000000000000007	3,5952	50,064573707787915	5,769086198067482
7	50,000000000000007	4,8935	50,068745509676361	6,031856735701116
8	50,000000000000007	6,3915	50,071808268491864	6,237571944242448
9	50,000000000000007	8,0893	50,074110392135310	6,403711477799382
10	50,000000000000007	9,9867	50,075879582270174	6,540435225560236
11	50,000000000000007	12,0839	50,077266843093945	6,654442835350952
12	50,000000000000007	14,3808	50,078374359077301	6,750129945141390
13	50,000000000000007	16,5481	50,079272784490790	6,832164461854908
14	50,000000000000007	19,5740	50,080012013455175	6,902947413503203
15	50,000000000000007	22,4701	50,080627987344279	6,964742862377626
16	50,000000000000007	25,5660	50,081147077898876	7,019252636072512
17	50,000000000000007	28,8617	50,081588965389280	7,067922796363431
18	50,000000000000007	32,3570	50,081968565714313	7,111857207549823
19	50,000000000000007	36,0521	50,082297345051636	7,151385259431947
20	50,000000000000007	39,9469	50,082584232666420	7,187082996008346
21	50,000000000000007	44,0415	50,082836265263339	7,219477388697100
22	50,000000000000007	48,3358	50,083059048887534	7,249000734715552
23	50,000000000000007	52,8298	50,083257094807443	7,276084465279777
24	50,000000000000007	57,5236	50,083434067029039	7,300988759887419
25	50,000000000000007	62,4171	50,083592966959046	7,323907899193610
26	50,000000000000007	67,5103	50,083736272767894	7,345038355461728
27	50,000000000000007	72,8033	50,083866045699878	7,364585896873854
28	50,000000000000007	78,2960	50,083984011979602	7,382712227879061
29	50,000000000000007	83,9884	50,084091626512276	7,399565944796050
30	50,000000000000007	89,8806	50,084190122854459	7,415282233471536
31	50,000000000000007	95,9725	50,084280552740402	7,430015621259824
32	50,000000000000007	102,2641	50,084363817584205	7,443838328876803

Nas Figuras 6.49 - 6.51 é possível verificar o sinal modulado original, o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 0.0998 Watt de acordo com a Tabela 6.16.




Figura 6.49 - Sinal modulado original com potência de 50 Watts usado no sistema de mistura 3.




Figura 6.50 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.




Figura 6.51 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.

A Figura 6.52 mostra o sinal modulado estimado considerando o sistema de mistura 3 para múltiplos percursos.




Figura 6.52 - Sinal modulado estimado considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 0.0998 Watt.

Na Figura 6.53 é possível visualizar o erro remanescente entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt para o sistema de mistura 3.




Figura 6.53 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 0.0998 Watt considerando sistema de mistura 3 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.16 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original. Porém, o erro médio é grande como pode ser visualizado através da Figura 6.53, e isso para um nível de potência de ruído baixo, 0.0998 Watt.

Nas Figuras 6.54 e 6.55 é possível verificar o sinal misturado 1 e o sinal misturado 2, respectivamente para uma potência de ruído de 102,2641 Watts de acordo com a Tabela 6.16.




Figura 6.54 - Sinal modulado normalizado misturado 1 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 102.2641 Watts.




Figura 6.55 - Sinal modulado normalizado misturado 2 considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 102.2641 Watts.

A Figura 6.56 mostra o sinal modulado estimado considerando o sistema de mistura 3 para múltiplos percursos para potência de ruído de 102.2641 Watts.




Figura 6.56 - Sinal modulado estimado considerando sistema de mistura 3 para múltiplos percursos com potência de ruído de 102,2146 Watts.

A Figura 6.57 mostra o erro remanescente entre o sinal modulado original e o sinal modulado estimado para o sistema de mistura 3 com potência de ruído de 120,2146 Watts.




Figura 6.57 - Erro entre o sinal modulado original e o sinal modulado estimado com potência de ruído de 102,2146 Watts considerando sistema de mistura 3 para múltiplos percursos.

É possível constatar através da análise da Tabela 6.16 que o algoritmo tenta manter o nível de potência do sinal estimado bem próximo do sinal original como para potências de ruídos mais baixas. Porém, o erro médio também aumenta à medida que a potência de ruído cresce, como nas Tabelas 6.12 e 6.14.

A Tabela 6.17 mostra os erros médios dos sinais quando aplicado deslocamentos temporais diferentes utilizando o sistema de mistura 3 em comparação aos valores dos erros médios da Tabela 6.16 utilizando deslocamento unitário e a potência de ruído usada foi sempre a mesma, 0,0998 Watt.

Tabela 6.17 - Erro médio considerando a variação do deslocamento temporal para uma potência de ruído de 0,0998 Watt para o sistema de mistura 3.

Deslocamento Temporal Variável		
Deslocamento Temporal	Potência do Sinal Estimado	Erro Médio
1	50,007393487220995	2,020308463842045
5	50,012548897844638	9,592161443089520
10	50,055907163245237	10,317347496725850
15	50,178192586225464	9,111323462257868
20	50,152550864207022	8,653733405684397
25	50,085762524282259	9,036994192992703
30	50,115058557530084	7,055571662857839
50	50,381530860458810	7,730599716528596
100	51,010107725350380	6,955093787284841

A conclusão ao analisar a Tabela 6.17 é a mesma que nas seções anteriores (Tabela 6.15 e 6.13), mesmo aumentando o deslocamento temporal pode ocorrer a diminuição do erro médio, visto que os algoritmos cegos aplicados neste trabalho não são os ideais para misturas convolucionais.

6.4.3.3.1 Análise Comparativa entre os Três Tipos de Misturas

A Figura 6.58 mostra a evolução da potência do sinal estimado para os três tipos de misturas (mistura 1, 2 e 3). A potência do sinal estimado para os sistemas de mistura 1 e 2 é bem parecida, tanto que no gráfico os sinais estão sobrepostos. Em contra partida, a potência do sinal estimado do sistema de mistura 3 desenvolve com uma pequena diferença das demais. Porém, essa diferença entre os sistemas de mistura, em relação a potência estimada, é muito pequena como pode ser verificada na Figura 6.58.




Figura 6.58 - Relação de potências estimadas para os sistemas de misturas 1, 2 e 3.

Na Figura 6.59 é possível verificar a evolução do erro médio do sinal estimado para os três tipos de misturas (mistura 1, 2 e 3), onde as potências de misturas 1 e 2 estão sobrepostas. Assim como a potência do sinal estimado na Figura 6.58, o erro médio também segue a mesma tendência, ou seja, os erro médios para as misturas 1 e 2 são bem parecidos. Entretanto, o erro médio do sinal estimado do sistema de mistura 3 se apresentou com uma pequena diferença dos demais. Porém, essa diferença entre os sistemas de mistura, em relação ao erro médio, é muito pequena como pode ser verificada na Figura 6.59.




Figura 6.59 - Relação de erros médios dos sinais estimados para os sistemas de misturas 1, 2 e 3.

As analisar as Figuras 6.58 e 6.59 pode-se concluir que o sistema de mistura 3 se destaca em relação a outros sistemas, apresentando um erro médio maior. Isso era esperado, pois esse sistema apresenta uma maior quantidade de deslocamento dos sinais, simulando mais múltiplos percursos dos sinais, visto uma vez que os algoritmos cegos aplicados no algoritmo proposto são para misturas instantâneas e não misturas convolucionais. Pois, o objetivo desse trabalho é inicialmente trabalhar em monitoramento de sinais únicos, ou seja, sondas com único sensor.

6.5 Considerações Finais deste Capítulo

Neste capítulo foram apresentados os resultados dos sinais analisados pelo algoritmo proposto nesse trabalho. Primeiramente, os sinais gerados através de ensaios práticos com extensômetros resistivos, depois os sinais gerados por Nunes (2012) [11] através da análise experimental e numérica de ensaios práticos. Em terceiro, foram utilizadas perfilagens térmicas de poços de várias cidades em dois Estados, Minas Gerais e Bahia, produzidas por Alexandrino (2008) [10]; e para finalizar aplicou-se o

algoritmo proposto em sinais teóricos.

CAPÍTULO 7

CONCLUSÕES

Neste capítulo, é analisada a validade do trabalho e a eficiência do algoritmo proposto, assim como são apresentadas as contribuições e sugestões para pesquisas futuras.

7.1 Análise dos Resultados Obtidos

Todos os testes mostraram que o algoritmo proposto se qualifica como uma ótima solução para o problema da presença de ruído em sinais monitorados. Os primeiros teste, usando sinais advindo de ensaios práticos com extensômetros, mostraram que o algoritmo proposto é uma ferramenta poderosa para detecção e redução de ruídos, pois o algoritmo proposto obteve resultados satisfatórios (Figura 6.2, Tabelas 6.1, 6.2 e 6.3). Além disso, apresenta resultados melhores que o equipamento utilizado nas simulações práticas [102], o qual é amplamente utilizado no mercado, isso pode ser verificado pelo resultado apresentado pelas métricas de performance utilizadas neste trabalho.

Observou-se também que os sinais na saída do algoritmo proposto obtiveram uma taxa de conversão muito maior que os sinais originais monitorados pelo equipamento. Uma vez que os extensômetros monitoraram praticamente o mesmo ponto, se não houvesse ruído, na teoria, os sinais dos dois extensômetros deveriam ser o mesmo.

Os segundos testes também aprontaram o algoritmo proposto como uma

ferramenta qualificada para a tarefa de detectar e reduzir níveis de ruído em sinais monitorados, uma vez que, os sinais apresentados pelo algoritmo proposto obtiveram uma taxa de conversão muito maior que os sinais originais (Tabela 6.4). A Tabela 6.5 mostra que os sinais do algoritmo proposto tiveram um ganho em relação aos sinais originais, confirmando a eficiência desse algoritmo.

Alguns resultados dos terceiros testes (perfilagem térmica) podem ser verificados na Tabela 6.8, sendo resultantes da comparação das Tabelas 6.6 e 6.7, apresentando um aumento considerável no gradiente térmico e uma redução no desvio padrão, isso é muito bom de acordo com a teoria de perfilagem geotérmica [10]. Assim, mais uma vez o algoritmo proposto se destaca como uma ferramenta poderosa e realmente útil.

Os últimos testes utilizando sinais gerados teoricamente foram divididos em três níveis de complexidade de sinais. O primeiro nível apresenta apenas um sinal senoidal simples como entrada no algoritmo proposto.

Ao analisar as simulações usando os sinais senoidais simples, é possível verificar que as potências do sinal estimado e do sinal original são praticamente iguais variando a potência do sinal de ruído (Tabela 6.10), onde a amplitude de variação da potência de ruído vai de cem vezes menor até o dobro da potência do sinal original.

Outro ponto que comprova a eficiência do algoritmo proposto é que mesmo variando a potência de ruído, com uma amplitude considerável, o erro estimado sofre uma pequena variação, confirmando a capacidade do algoritmo de detectar e reduzir ruídos para diferentes amplitudes de potência.

O segundo nível de complexidade de sinais gerados teoricamente, utilizou um sinal modulado usando a tecnologia BPSK [111]. Ao analisar os resultados (Tabela 6.11) pode-se concluir que o algoritmo proposto aplicado nesse tipo de sinal também

apresentou um resultado muito satisfatório, erro estimado de aproximadamente 10^{-9} , um pouco maior que para sinais senoidais simples (10^{-11}), mas mesmo assim, ainda um excelente resultado.

Assim, comprova a eficiência do algoritmo proposto uma vez que ele mantém a potência do sinal estimado independente da potência de ruído. Com essa característica esse algoritmo é uma excelente ferramenta para aplicação em várias áreas de monitoramento.

Para o terceiro nível de complexidade de análise, foram utilizados sinais que consideram a influência do efeito de múltiplos percursos [112]. Três sistemas de mistura foram aplicados, simulando os caminhos de múltiplos percursos, os dois primeiros apresentaram resultados bem semelhantes, já o terceiro apresentou diferença nos resultados. Essa diferença já era prevista, pois é o sistema de mistura onde se aplica mais deslocamentos temporais.

Os resultados apresentados pelo algoritmo proposto para os sinais do terceiro nível não foram satisfatórios, porém esse resultado já era esperando, já que os algoritmos cegos utilizados pelo algoritmo proposto foram desenvolvidos para misturas instantâneas e não para misturas convolutivas. Mesmo assim, são resultados importantes para confirmar a eficiência do algoritmo proposto, pois realmente a tecnologia aplicada nele não é capaz de estimar sinais com misturas convolutivas.

Ao analisar todos os resultados apresentados pelo algoritmo proposto é possível concluir que ele realmente supre várias demandas do mercado atual, como as relatadas inicialmente por vários pesquisadores na área, como: ferramenta que não utilize filtros ativos para redução de ruídos, aplicação com custo realmente baixo, não necessita de informações a priori dos sinais monitorados, possui baixa complexidade computacional, executa uma análise puramente estatística, etc.

Assim, diante dessas necessidades supridas, o algoritmo proposto se confirma como uma ferramenta útil para detecção e redução de ruído em sinais monitorados considerando misturas instantâneas.

7.2 Contribuições do Trabalho

O algoritmo proposto atende a todos os objetivos indicados inicialmente. Assim, esse trabalho fornece como contribuições principais:

- Proposição do algoritmo para detecção e redução de ruído em sinais monitorados em várias áreas baseado na tecnologia BSS como ferramenta, que seja eficiente, barato e inovador;
- Validação do algoritmo aplicando vários tipos de sinais usando diferentes tipos de métricas para análise;
- Confirmação que os algoritmos utilizados pela BSS são eficientes apenas para misturas instantâneas, e não para misturas convolutivas.

Com os objetivos deste trabalho atendidos, a primeira contribuição foi alcançada com êxito. Assim sendo, o artigo intitulado “*Noise Removal in Monitoring Sensors of Civil Structures using Blind Source Separation*” foi aceito e será publicado na versão de dezembro de 2016 da revista *International Journal of Innovative Computing, Information & Control* – Japão.

Existem ainda dois artigos submetidos, o primeiro na revista IEEE Latino Americana intitulado “*Blind Source Separation using Maximun Signal Noise Ratio Algorithm for Noise Removal in Monitoring Sensors*”, e o segundo na revista *Latin American Applied Research* intitulado “*A Survey of Blind Source Separation for Noise*

Removal Applications in Thermal Profiling”.

Com relação à segunda contribuição principal deste trabalho, observou-se através de diversas simulações e análises uma redução considerável dos níveis de ruídos em todos os sinais analisados, e consequentemente, um aumento das métricas utilizadas como a Relação Sinal Ruído (SNR), Relação Sinal Distorção (SDR) e Relação Sinal Interferência (SIR).

7.3 Sugestões para Trabalhos Futuros

Uma sugestão pode ser feita para otimizar o algoritmo proposto neste trabalho, aproveitar com base os estudos desenvolvidos nesta pesquisa e desenvolver algoritmos que possam ser aplicados em sinais convolutivos, pois esse tipo de consideração pode deixar as análises ainda mais fieis à realidade aumentando a variedade de aplicações e assim, ficando ainda mais genérico.

BIBLIOGRAFIA

- [1] G. Nery, “Monitoreo em la construcción civil - Boletín técnico”, Asociación Latinoamericana de Control de Calidad, Patología y Recuperación de la Construcción – ALCONPAT Int., 18p., 2013.
- [2] T. F. Collura, “History and evolution of electroencephalographic instruments and techniques”, Clinical Neurophysiology, vol.10, no.4, pp.476-504, 1993.
- [3] I. M. Artemieva and W. D. Mooney, “Thermal Structure and Evolution of Precambrian Lithosphere: A Global Study”, J. Geophys, vol.106, pp.16387-16414, 2001.
- [4] F. A. Branco and P. V. Paulo, “O Projecto de Pontes para Vidas superiores a 100 anos”, Revista de la Asociación Latinoamericana de Control de Calidad, Patología y Recuperación de la Construcción, ALCONPAT, 2012.
- [5] D. Balageas, C. P. Fritzen, and A. Guemes, “Structural Health Monitoring”, ISTE, USA, 2006.
- [6] J. M. W. Brownjohn, “Structural Health Monitoring of Civil Infrastructure”, The Royal Society, 2007.
- [7] B. Peeters and G. De Roeck, “Stochastic System Identification for Operational Modal Analysis: a Review”, J. Dyn. Syst. Meas. Control 123, p.659-667, 2001.
- [8] M. Jiancang and Z. Xiaobing, “Blind Source Separation Algorithm based on Maximum Signal Noise Ratio”, First International Conference on Intelligent Networks and Intelligent Systems, 2008.
- [9] V. C. M. N. Leite, “Separação Cega de Sinais: Análise Comparativa entre Algoritmos”, 253p., Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá, Itajubá, Minas Gerais, 2004.

- [10] C. H. Alexandrino, “Campo Termal da Província Estrutural São Francisco e Faixas Móveis Adjacentes”, 184p., Tese (Doutorado em Geofísica) – Observatório Nacional, Rio de Janeiro, Rio de Janeiro. 2008.
- [11] G. V. Nunes, Análise numérica paramétrica de ligações tipo “T”, “K” e “TK” compostas por perfis tubulares de seção retangular e circular, 124p., Dissertação (Mestrado em Engenharia Civil) – Universidade de Ouro Preto, Ouro Preto, Minas Gerais, 2012.
- [12] F. F. M. Santos, “Uso de Extensômetros para Altas Temperaturas na Estimativa de Vida Residual – Monitoração em Tempo Real das Deformações de Tubulações em Usinas de Geração Térmica”, 111p., Dissertação (Mestrado em Engenharia Metalúrgica e de Materiais) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, Rio de Janeiro, 2011.
- [13] EPRI, “Technical Report. Fleetwide Monitoring for Equipment Condition Assessment”, EPRI, Palo Alto, 2006.
- [14] K. Hoffmann, “An Introduction to Measurements using Strain Gages”, Hottinger Baldwin Messtechnik GmbH, Darmstadt, 1989.
- [15] A. L. Window and G. S. Holister, “Strain Gage Techonolgy Applied”, Science Publishers, London and New York, 1982.
- [16] R. W. R. Ataíde, “Projeto e Implementação de um Nodo Sensor para Aquisição de Sinais de Extensômetros em Redes de Sensores sem Fio aplicado ao Monitoramento de Deformações em Estruturas”, 86p., Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pará, Belém, Pará, 2012.
- [17] K. Bethe, “The scope of the strain gage principle, IEEE, VLSI and Computer Peripherals, VLSI and Microelectronic Applications in Intelligent Peripherals and their Interconnection Networks”, CompEuro, pp.31-38, Hamburg, Germany, 1989.

- [18] B. Studyvin, R. L. Doty and R. Repplinger, “Temperature effects on strain gages used on aerospace nickel hydrogen batteries”, IEEE, Battery Conference on Applications and Advances, pp.325-328, Long Beach, CA, USA, 1999.
- [19] L. Picciano and J. K. J. Li, “A novel strain gage transducer design for biomedical applications”, IEEE, Engineering in Medicine and Biology Society, vol.12, no.2, pp.512-513, 1990.
- [20] J. E. Ramus, “Radiation induced electrical transients in strain gage and temperature transducer circuits in a pulsed reactor environment”, IEEE, Nuclear Science, vol.11, no.5, pp.111-122, 1964.
- [21] O. T. Gregory and X. Chen, “A low TCR nanocomposite strain gage for high temperature aerospace applications”, IEEE, Sensors, pp.624-627, 2007.
- [22] S. Poussier, H. Rabah and S. Weber, “Design and implementation of a smart strain gage conditioner”, IEEE International Workshop on Computer Architectures for Machine Perception, pp.184-192, 2003.
- [23] C. R. Shearer, “Temperature compensation of transducers using semiconductor strain gages”, IEEE Transactions on Aerospace, vol.3, no.2, pp.53-59, 1965.
- [24] ASM, “Nondestructive Evaluation and Quality Control, Metals Handbook”, v.17. Metals Park, Ohio, 1989.
- [25] R. P. Andolfato, J. S. Camacho and G. A. Brito, “Extensometria Básica”, Universidade Estadual Paulista, Ilha Soleira, SP, 2004.
- [26] A. Milton and I. G. B. Zaro, “Extensômetros de Resistência Elétrica – Strain Gauges”, 1982.
- [27] V. L. A. Camargo, “Desenvolvimento e Implementação de uma Plataforma para Monitoramento Estrutural utilizando Sensores Extensométricos Conectados em Rede”, 189p., Dissertação (Mestrado em Engenharia de Controle e Automação) –

Universidade Estadual de Londrina, Londrina, Paraná, 2008.

- [28] R. R. Magalhães, “Avaliação do uso da Extensometria na Análise de Tensões Residuais de Soldagem”, 129p., Dissertação (Mestrado em Engenharia Mecatrônica) – Universidade Federal da Bahia, Salvador, Bahia, 2008.
- [29] M. V. Exter, “Noise and signal processing”, Extra syllabus for (third-year) course, Universiteit Leiden, 2003.
- [30] F. C. Simões, “Estudo da relação sinal – ruído na aquisição de dados de sensores de alta impedância”, Dissertação de graduação, Universidade Estadual de Campinas, 2008.
- [31] A. P. Silva, “Separação cega de misturas convolutivas no domínio do tempo utilizando clusterização”, 63p., Dissertação (mestrado em Eletrônica e Computação) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2009.
- [32] B. P. Lathi, “Modern Digital and Analog Communication Systems”, Third Edition, 401p., Oxford university press, New York, 1998.
- [33] A. A. Farias, J. F. Soares and C. C. César, “Introdução à Estatística” 2ed., pp. 340, Editora LTC, Rio de Janeiro, 1998.
- [34] L. J. Oliveira, “Avaliação do uso da perfilagem geofísica para obtenção de informações secundárias para utilização em co-estimativas de variáveis geológico-mineiras, 183p., Dissertação (Mestrado em Engenharia de Minas) – Universidade Federal do Rio Grande do Sul, Porto Alegre, Rio Grande do Sul, 2005.
- [35] D. V. Ellis and J. M. Singer, “Well logging for earth scientist, 692p., Springer, 2008.
- [36] M. Assumpção, T. H. Yamabe e V. Hamza, “Estudos geotérmicos em Bebedouro: implicações para ocorrência das atividades sísmicas”, Relatório informativo das perfilagens geofísicas, 29p., São Paulo, 2006.

- [37] A. Hyvarinen, J. Karhunen and E. Oja, “Independent component analysis”, 481p., Nova York: J. Wiley, 2001.
- [38] A. Cichocki and S. I. Amari, “Adaptive blind signal and image processing: learning algorithms and applications”, John Wiley & Sons, 2002.
- [39] S. V. Schell and W. A. Gardner, “Maximum Likelihood and Common Factor Analysis Based Blind Adaptive Spatial Filtering for Cyclostationary Signals”, In Proc. of IEEE ICASSP, v.4, p.292-295, 1992.
- [40] X. Cao and R. Liu, “General Approach to Blind Source Separation”, IEEE Trans. On Signal Processing, 44(3), p.562-571, 1996.
- [41] P. Comon, “Independent Component Analysis: A New Conception?”, Signal Processing Special Issue on High Order Statistics, n. 36, p.287-314, 1994.
- [42] J. F. Cardoso, “Blind Separation: Statistical Principles”, Proceedings of IEEE, p.2009-2025, 1998.
- [43] L. R. Silva, “Aplicação da Decomposição em Valores Singulares e Análise de Componentes Independentes em Dados de FMRI”, 53p., Dissertação (Mestrado em Matemática) – Universidade Federal do Pará, Belém, Pará, 2011.
- [44] A. Hyvarinen, “One Unit Contrast Function for Independent Component Analysis: A Statistical Analysis”, IEEE Workshop on Neural Network for Signal Processing, p.388-397, Florida, 1997.
- [45] A. Bell and T. J. Sejnowski, “An information maximization approach to blind separation and deconvolution”, Neural Computing, vol.7, n.6, pp.1129-1159, 1995.
- [46] T. W. Lee, M. Girolami, A. J. Bell and T. J. Sejnowski, “A Unifying Information – Theoretic Framework for Independent Component Analysis”, Computers & Mathematics with Application, 31(11), p.1-21, Mar., 1998.
- [47] A. Hyvarinen and E. Oja, “Independent Component Analysis: Algorithms and

- Applications”, *Neural Networks*, 13(4-5), p. 411-430, 2000.
- [48] A. Hyvarinen and E. Oja, “A Fast Fixed Point Algorithm for Independent Component Analysis”, *Neural Computation*, 9(7), p.1483-1492, 1997.
- [49] I. C. C. Leite, “Análise de Componentes Independentes Aplicada a Avaliação de Imagem Radiográfica de Sementes”, 124p. Tese (Doutorado em Estatística) – Universidade de Lavras, Lavras, Minas Gerais, 2013.
- [50] C. C. Cavalcante, “Sobre Separação Cega de Fontes: Proposições a Análise de Estratégias para Processamento Multi-Usuário”, 297p., Tese (doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, SP, 2004.
- [51] F. A. L. Moreto, “Análise de Componentes Independentes Aplicada à Separação de Sinais de Áudio”, Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Paulo, São Paulo, 2008.
- [52] A. Hyvarinen, “Survey on independent component analysis”, *Neural Computing Surveys*, vol.2, pp.94-128, 1999.
- [53] J. F. Cardoso, “Infomax and Maximum Likelihood for Source Separation”, *IEEE Letters on Signal Processing*, v.4, n.4, p.112-114, Abril, 1997.
- [54] J. F. Cardoso, “High – Order Contrast for Independent Component Analysis”, *Neural Computation*, v. 11, n.1, p.157-192, Jan., 1999.
- [55] S. I. Amari, “Estimating Functions of Independent Component Analysis for Temporally Correlated Signals”, *Neural Computation*, 12(9), p.2083-2107, 2000.
- [56] J. Karhunen, E. Oja, L. Wang and J. Koutsensalo, “A Class of Neural Networks for Independent Component Analysis”, *IEEE Trans. On Neural Networks*, v.8, n.3, p.486-504, May., 1997.
- [57] C. Jutten and J. Héroult, “Blind Separation of Sources: An Adaptive Algorithm based on Neuromimetic Architecture”, *Signal Processing*, v.24, p.1-10, 1991.

- [58] A. Papoulis, “Probability, Random Variables and Stochastic Process”, Mc Graw Hill, 3ed., 1991.
- [59] B. Picinbono, “Random signals and systems”, Englewood Cliffs, New Jersey: Prentice Hall International Editions, 1993.
- [60] S. Haykin, “Blind deconvolution”, New Jersey, USA, Prentice Hall, Englewood Cliffs, 1994.
- [61] C. C. Cavalcante, “Predição Neural e Estimação de Função Densidade de Probabilidade Aplicadas à Equalização Cega”, 158p. Tese (Mestrado em Engenharia Elétrica) – Universidade Federal do Ceará, Fortaleza, Ceará, 2001.
- [62] C. E. Shannon, “A Mathematical Theory of Communication”, Bell Systems Technical Journal, vol.27, pp.379-423, 1948.
- [63] J. D. Gibson, “Principles of Digital and Analog Communications”, Prentice Hall, New Jersey, USA, 1993.
- [64] S. Haykin, “Neural Networks: A Comprehensive Foundation”, Prentice Hall, 1998.
- [65] S. Kullback and R. A. Leibler, “On information and sufficiency”, Annals of Mathematical Statistic, p.32, 1951.
- [66] G. Deco and D. Obradovic, “An Information-Theoretic Approach to Neural Computing”, p.32, Springer-Verlag, 1996.
- [67] J. R. F. Montalvão, “Égalisation et Identification de Canaux de Communication Numérique: Une Approche par Reconnaissance des Formes et Mélange de Gaussiennes”, 197p. Tese (Doutorado em Estatística) – Université Paris XI, Paris, France, 2000.
- [68] E. Kofidis, “Blind Source Separation: Fundamentals and Recent Advances”, XIX Simpósio Brasileiro de Telecomunicações (SBrT2001). Fortaleza, CE, Set., 2001.
- [69] A. Touzni, “Performance et Robustesse en Égalisation Aveugle Spatio-Temporelle”,

- 197p., Tese (Doutorado em Engenharia Elétrica) – Université de Cergy-Pontoise, France, 1998.
- [70] S. Haykin, “Unsupervised Adaptive Filtering”, John Wiley & Sons, 2000.
- [71] H. H. Yang and S. Amari, “Adaptive On-line Learning Algorithms for Blind Separation: Maximum Entropy and Minimum Mutual Information”, *Neural Computation*, vol.9, pp.1457-1482, 1997.
- [72] S. A. C. Alvarez, “Una visión unificada de los algoritmos de separación ciega de fuentes”, Tese (Doutorado em Engenharia Elétrica), Universidade de Vigo, 1999.
- [73] D. T. Pham and J. F. Cardoso, “Blind Separation of Instantaneous Mixtures of Nonstationary Sources”, *Proc. Of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2000)*, p.187-193, Helsinki, 2000.
- [74] A. F. Barbosa, “Um Sistema Inteligente de Classificação de Sinais de EEG para Interface – Cérebro Computador”, 46p., Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Norte, Natal, Rio Grande do Norte, 2012.
- [75] A. Jain, “Fundamentals of Digital Image Processing”, Prentice Hall, Nova Jersey, 3 ed. 1989.
- [76] S. V. Poblador, E. M. Moreno and J. S. Casal, “ICA as a Preprocessing Technique for Classification”, In *Proceedings of the Fifth International Workshop on Independent Component Analysis and Blind Signal Separation, ICA 2004*, pp.1165-1172, Granada, Espanha, 2004.
- [77] Z. Kun and L. W. Chan, “ICA by PCA Approach: Relating Higher-Order Statistics to Second-Order Moments”, 2006.
- [78] C. C. S. Almeida, “Análise de Técnicas Separação Cega de Fontes para Remoção

- de Artefatos em Interfaces Cérebro – Máquina”, 86p., Dissertação (mestrado em Engenharia da Informação) – Universidade Federal do ABC, Santo André, SP, 2013.
- [79] R. Suyama, “Proposta de Métodos de Separação Cega de Fontes para Misturas Convolucionais e Não-Lineares”, 184p., Tese (doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, SP, 2007.
- [80] L. Yang and Z. Ming, “Blind source separation based on fastICA”, Ninth International Conference on Hybrid Intelligent Systems, vol.2, pp.475-479, 2009.
- [81] J. F. Cardoso, “Source Separation using Higher Order Moments”, In Proceedings of IEEE Int. Conference on Acoustics, Speech and Signal Processing (ICASSP’89). pp.2109-2112, Glasgow, Scotland, 1989.
- [82] P. Comon, “Separation of Sources using Higher Order Cumulants”, In SPIE Conference on Advanced Algorithms and Architectures for Signal Processing, pp.170-181, San Diego, California, USA, 1989.
- [83] J. F. Cardoso and A. Souloumiac, “A blind beam-forming for non-gaussian signals”, IEEE, Proc. Part F, vol.140, n.6, pp.362-370, 1993.
- [84] A. Hyvarinen, “Gaussian moments for noisy independent component analysis”, IEEE Signal Processing Letters, vol.6, n.6, pp.145-147, 1999b.
- [85] C. R. Farrar and K. Worden, “An introduction to structural health monitoring”, Philosophical Transactions of The Royal Society, vol.365, no.1851, pp.303-315, 2006.
- [86] V. Zarzoso and A. K. Nandi, “Noninvasive fetal electrocardiogram extraction: blind separation versus adaptive noise cancellation”, IEEE Transactions on Biomedical Engineering, vol.48, n.1. Janeiro, 2001.
- [87] J. V. Stone, “Independent component analysis: an introduction”, TRENDS in

- cognitive sciences, vol.6, n.2, Fevereiro, 2002.
- [88] G. He, L. Clifford and L. Tarassenko, “Application of independent component analysis in removing artefacts from the electrocardiogram”. *Neural comput & applic*, vol.15, pp.105-116, 2006.
 - [89] M. Ferdjallah and R. E. Barr, “Adaptive digital notch filter desing on the unit circle for the removal of powerline noise from biomedical signals”, *IEEE Transactions on Biomedical Engineering*, vol.41, n. 6, Junho, 1994.
 - [90] E. A. Clansy, E. L. Morin and A. Merletti, “Sampling, noise-reduction and amplitude estimation issues in surface electromyography”, *Journal of electromyography and Kinesiology*. n.12, pp.1-16, 2002.
 - [91] H. H. Asada, H. H. Jiang and P. Gibbs, “Active noise cancellation using MEMS accelerometers for motion-tolerant wearable bio-sensors”, *Proceedings of the 26th annual international conference of the IEEE EMBS*. pp.1-5, São Francisco, CA, USA, Setembro, 2004.
 - [92] P. C. Chang, A. Flatau and S. C. Liu, “Review paper: health monitoring of civil structure”, *Structure health monitoring*, 2010.
 - [93] F. Odille, C. Pasquier, R. Abacherli, P. A. Vuissoz, G. P. Zientara and J. Felblinger, “Noise Cancellation signal processing method and computer system for improved real-time electrocardiogram artifact correction during MRI data acquisition”, *IEEE Transactions on Biomedical Engineering*, vol.54, n.4, Abril, 2007.
 - [94] D. C. B. Chan, “Blind signal separation”, PhD Thesis, Signal Processing and Communications Lab, Department of Engineering, University of Cambridge, UK, Jan., 1997.
 - [95] J. V. Stone, “Blind source separation using temporal predictability”, *Neural Computation*, vol.13, pp.1559-1574, 2001.

- [96] J. Ma, X. Zhang, Blind source separation algorithm based on maximum signal noise ratio, First International Conference on Intelligent Networks and Intelligent Systems, pp.625-628, 2008.
- [97] W. L. Hwang, J. Ho, Null space component analysis for noisy blind source separation, ScienceDirect, Signal Processing, vol.109, pp.301-316, 2015.
- [98] E. Vicent, R. Gribonval and C. Févotte, Performance measurement in blind audio source separation, *IEEE Transactions on Audio, Speech, and Language Processing*, vol.14, no.4, pp.1462-1469, July, 2006.
- [99] W. F. Lages, *Probabilidade e variáveis aleatórias*, Departamento de engenharia elétrica, Universidade federal do rio grande do sul, 2004.
- [100] M. Borga, Learning multidimensional signal processing, Unpublished Doctoral Dissertation Linkoping University, Linkopig, Sweden, 1998.
- [101] S. Eglen, A. Bray, J. Stone, Unsupervised discovery of invariances, *Network: Comput. Neural Syst.*, vol.8, pp.441-452, 1997.
- [102] HBM, Data sheet: spider 8, pp.8, 2012.
- [103] G. C. Dotti, “Interpretação Quantitativa de Campos de Potencial Espontâneo na Perfilagem Geofísica de Poços”, 72p., Dissertação (Mestrado em Geofísica) – Universidade de São Paulo, São Paulo, São Paulo. 2008.
- [104] R. Haenel, F. Mongelli, “Thermal Exploration Methods”, *Handbook of Terrestrial Heat-Flow Density Determination*, pp.353-389. 1988.
- [105] V. M. Hamza and M. Muñoz, Heat Flow Map of South America, *Geothermics*, vol.25, n.6, pp.599-646, Inglaterra. 1996.
- [106] V. M. Hamza, F. J. S. S. Dias, A. J. L. Gomes, Z. G. D. Terceros, Numerical and Functional Representations of Regional Heat Flow in South America, *PEPI*, vol.154, n.4, pp.223-256. 2005.

- [107] O. R. Fournier, Water Geothermometers Applied to Geothermal Energy, Ed. D'Amore F., New York. 1991.
- [108] S. P. Verma and E. Santoyo, New Improved Equations for Na/K and SiO₂ Geothermometers by Error Propagation, World Geothermical Congress, Florence, Italy. 1995.
- [109] V. M. Hamza, S. M. Eston, R. L. C. Araújo, I. O. Vitorello e N. Eussami, “Levantamento de Dados de Geothermal Brazilian Series-1”, Instituto de Pesquisa Tecnológicas do Estado de São Paulo – IPT, n.1109. 1978.
- [110] S. Haykin, M. Moher, “Introdução aos sistemas de comunicação”, 2ªed, Bookman, Porto Alegre, 2008.
- [111] A. M. P. Lucena, P. D. L. Oliveira, C. S. N. Rios, M. P. A. Filho, D. B. Pimentel, K. M. H. Coutinho e F. A. T. F. Silva, “Gerador de Sinais BPSK em FPGA para Aplicações Espaciais”, INPE, São José dos Campos, 2014.
- [112] A. C. Ferreira, “Modulação Codificada sobre Múltiplas Portadoras em Canais com Múltiplos Percursos Variantes no Tempo”, 84p., Dissertação (mestrado em Eletrônica) – Instituto Nacional de Telecomunicações, Santa Rita do Sapucaí, MG, 2008.
- [113] Conferência Internacional sobre Análise de Componentes Independentes e Separação Cega (ICAZ2003).
- [114] A. A. Filho, Elementos finitos – a base da tecnologia, pp. 304, Editora Érica, Rio de Janeiro, 2005.