

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO TECNOLÓGICO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**COMPARAÇÃO DE MÉTODOS PARA DETECÇÃO DE OSCILAÇÕES  
EM UNIDADES INDUSTRIAIS AFETADAS POR DISTÚRBIOS**

DISSERTAÇÃO DE MESTRADO

ROBERTO VIEIRA JUNIOR

VITÓRIA

2016

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO TECNOLÓGICO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**COMPARAÇÃO DE MÉTODOS PARA DETECÇÃO DE OSCILAÇÕES  
EM UNIDADES INDUSTRIAIS AFETADAS POR DISTÚRBIOS**

ROBERTO VIEIRA JUNIOR

Dissertação de Mestrado apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Celso José Munaro

VITÓRIA

2016

Dados Internacionais de Catalogação-na-publicação (CIP)  
(Biblioteca Setorial Tecnológica,  
Universidade Federal do Espírito Santo, ES, Brasil)

---

V657c Vieira Junior, Roberto, 1986-  
Comparação de métodos para detecção de oscilações em  
unidades industriais afetadas por distúrbios / Roberto Vieira  
Junior. – 2016.  
86 f. : il.

Orientador: Celso José Munaro.  
Dissertação (Mestrado em Engenharia Elétrica) –  
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Detecção de oscilações. 2. Oscilações. 3. Análise de  
Componentes Independentes (ICA). 4. Envelope espectral. 5.  
Função de autocorrelação. I. Munaro, Celso José. II.  
Universidade Federal do Espírito Santo. Centro Tecnológico. III.  
Título.

CDU: 621.3

---

**ROBERTO VIEIRA JUNIOR**

**COMPARAÇÃO DE MÉTODOS PARA DETECÇÃO DE  
OSCILAÇÕES EM UNIDADES INDUSTRIAIS AFETADAS POR  
DISTÚRBIOS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

Aprovada em 25, de novembro de 2016.

**COMISSÃO EXAMINADORA:**



---

Prof. Dr. Celso José Munaro  
Universidade Federal do Espírito Santo  
Orientador



---

Prof. Dr. André Laurindo Maitelli  
Universidade Federal do Rio Grande do Norte



---

Dr. Mario Cesar Mello Massa de Campos  
CENPES/Petrobras

*"No meio de qualquer dificuldade encontra-se a oportunidade."*

*(Albert Einstein)*

## **Agradecimentos**

A Deus, por me guiar pelos caminhos certos. A minha família, por sempre me apoiar em todos os momentos da minha vida. Ao meu orientador, Celso Munaro, por toda a sua dedicação e conselhos na elaboração deste trabalho. A todo o pessoal do LCI, que durante estes dois anos foram muito mais do que companheiros de trabalho, mas foram também amigos e grandes incentivadores. À minha esposa, Mirella, pela compreensão em minha ausência, pelo seu apoio, carinho e por todo o incentivo concedido na elaboração deste trabalho. Aos meus amigos, que sempre estiveram presentes em minha vida.

Muito obrigado!

## Resumo

Detectar a presença de oscilações em processos industriais permite corrigir rapidamente seus efeitos nocivos. Quatro importantes métodos da literatura são analisados e comparados neste trabalho: Função de Autocorrelação, Envelope Espectral, Análise de Componentes Independentes e Transformada Discreta de Cosseno. A comparação é feita com sinais de uma planta industrial com múltiplas frequências de oscilação, presença de ruídos e distúrbios, e oscilações de diferentes amplitudes. Considerando-se os requisitos de equipes de operação, propostas são apresentadas aos diferentes métodos para caracterizar as oscilações que mais impactam na variabilidade dos sinais analisados, orientando as equipes para a rápida identificação de suas fontes. É proposta também a aplicação de uma metodologia com a finalidade de selecionar dados livres de *outliers* e distúrbios acentuados, que interferem nos resultados obtidos pelos algoritmos de detecção de oscilações. A metodologia proposta é aplicada a dados coletados de uma planta industrial. Por fim, um método de detecção de oscilações é aplicado sobre janelas de dados sequenciais com o objetivo de avaliar a repetibilidade dos resultados obtidos em análises sucessivas.

## **Abstract**

Detecting the presence of oscillations in industrial processes allows to quickly correcting the damaging effects that they produce. Four important methods in the literature are analysed and compared in this work: Autocorrelation Function, Spectral Envelope, Independent Component Analysis and Discrete Cosine Transform. The comparison is made with signals of an industrial plant with multiple oscillation frequencies, the presence of noise and disturbances, and oscillations of different amplitudes. Considering the operations staff requirements, proposals are presented to the different methods to characterize the oscillations that most impact in the variability of the signals analyzed, guiding staff to quickly identify their sources. A methodology is proposed to select data free of outliers and severe disturbances that interfere in the results obtained by the oscillation detection algorithms. The proposed methodology is applied to data collected from an industrial plant. Finally an oscillation detection method is applied a moving window data to evaluate the repeatability of the results obtained on successive analysis.



## Lista de Figuras

Figura 2.1. Seleção das bandas de frequências dominantes. ....	21
Figura 2.2. Seleção das bandas de frequências dominantes. ....	23
Figura 2.3. Sinal $x_1(nh)$ no tempo (superior) e DCT desse sinal (inferior). ....	36
Figura 2.4. DCT do sinal $x_1(nh)$ após a aplicação do limiar $SL_1$ e as três componentes selecionadas no domínio do tempo. ....	36
Figura 2.5. DCT do sinal $x_1(nh)$ após a aplicação do limiar $SL_2$ e as duas componentes selecionadas no domínio do tempo. ....	37
Figura 3.1. Passos da DFT utilizando janela retangular para truncamento dos dados. ....	41
Figura 3.2. Espectro de um sinal de características oscilatórias com e sem a aplicação de uma janela de Gauss. ....	42
Figura 3.3. Exemplo de cálculo do CVE como indicativo da variabilidade de cada oscilação detectada. ....	48
Figura 3.4. Sinais industriais e suas densidades espectrais de potência. I-Sinais no tempo; II-PSD dos sinais sem pré-tratamento; III-PSDs dos sinais após a utilização de pré-tratamento. ....	50
Figura 3.5. Resultados obtidos pelos algoritmos de detecção para os 8 sinais. ....	52
Figura 3.6. Picos com energias relevantes selecionados nas PSDs dos 8 sinais pelo método ACF (áreas em amarelo). ....	53
Figura 3.7. DCT e DCT inversa dos 8 sinais industriais. I-DCT dos sinais; II-DCT inversa dos segmentos selecionados (sinais no tempo). ....	54
Figura 3.8. Envelope espectral para os 8 sinais. ....	55
Figura 3.9. Picos com energias relevantes selecionados nas componentes independentes determinadas pelo método ICA (áreas em amarelo). ....	55
Figura 3.10. Resultados dos algoritmos de detecção para os 8 sinais após a aplicação do teste de regularidade. ....	56
Figura 3.11. Coeficiente de variação. I-CV de cada um dos 8 sinais; II-CVE das oscilações detectadas em cada sinal; III-CVE total para cada período de oscilação regular detectado. ....	57
Figura 4.1. Sinais industriais com presença de distúrbios antes e depois da utilização de filtro de pré-tratamento. ....	60
Figura 4.2. PSDs dos sinais sem a utilização de filtro de pré-processamento. ....	60
Figura 4.3. Metodologia para descarte de distúrbios e outliers. ....	61

Figura 4.4. Sinais de processo avaliados pelo algoritmo de descarte de distúrbios e outliers e classes utilizadas na seleção dos dados.....	62
Figura 4.5. Metodologia para descarte de distúrbios e outliers. ....	63
Figura 4.6. Sinais 1 a 32 no tempo: dados selecionados em vermelho e dados descartados em azul. ....	65
Figura 4.7. PSDs dos 32 sinais sem a aplicação de pré-tratamento e sem a aplicação da metodologia de seleção de dados regulares. ....	67
Figura 4.8. PSDs dos 32 sinais após a aplicação de um tratamento adequado sobre os sinais. ....	68
Figura 4.9. Períodos detectados em cada um dos 32 sinais. ....	69
Figura 4.10. CVE acumulado de cada grupo de oscilações detectado. ....	70
Figura 4.11. Número de sinais afetados por cada grupo de oscilações detectado. ....	70
Figura 4.12. CVE para as três oscilações principais.....	71
Figura 4.13. Componentes principais versus variância para o conjunto de PSDs dos sinais analisados.....	72
Figura 4.14. Sinais 1 a 32 no tempo para o dia 2: dados selecionados em vermelho e dados descartados em azul.....	73
Figura 4.15. Sinais 1 a 32 no tempo para o dia 3: dados selecionados em vermelho e dados descartados em azul.....	74
Figura 4.16. Sinais 1 a 32 no tempo para o dia 4: dados selecionados em vermelho e dados descartados em azul.....	75
Figura 4.17. Percentual médio de retenção de dados para as quatro análises sequenciais efetuadas sobre os 32 sinais.....	76
Figura 4.18. Gráficos gerenciais para os 4 dias analisados: três principais oscilações detectadas (superior) e CVEs associados a essas oscilações (inferior). ....	77
Figura 4.19. Períodos detectados em cada um dos 32 sinais para os quatro dias.....	78
Figura 4.20. CVE de cada grupo de oscilações detectado para os quatro dias.....	79
Figura 4.21. CVE para as três oscilações principais durante os quatro dias. ....	80
Figura 4.22. Sinais 20 e 25 no tempo ao longo dos quatro dias analisados.....	81

## Lista de Tabelas

Tabela 2.1. Resultados obtidos após a aplicação do limiar $SL_1$ . .....	37
Tabela 2.2. Resultados obtidos após a aplicação do limiar $SL_2$ . .....	38
Tabela 3.1. Tempo de execução dos algoritmos.....	39
Tabela 3.2. Parâmetros utilizados nas configurações dos métodos. ....	51

## Simbologia e abreviaturas

$\Phi_x$	- PSD
$\Phi_{N_x}$	- PSD normalizada
$f$	- Frequência
$r_{xx}$	- Sinal autocorrelacionado
$\omega$	- Frequência angular
$\mathcal{E}_P$	- Limiar de potência usado no método ACF
$\mathcal{E}_E$	- Limiar de energia usado no método ACF
$f_L$	- Frequência inferior do filtro passa-faixa
$f_U$	- Frequência superior do filtro passa-faixa
$\mu$	- Valor médio
$\sigma$	- Desvio padrão
$\Delta f$	- Largura do filtro passa-faixa
$\overline{T_p}$	- Média dos períodos
$\sigma_{T_p}$	- Desvio padrão dos períodos
$r$	- Índice de regularidade dos períodos
$K_\sigma$	- Escalar empregado para controle do agrupamento das oscilações detectadas
$X$	- Matriz contendo um conjunto de observações do processo
$V_x$	- Matriz de covariância de $X$
$P_x$	- Espectro cruzado de $X$
$\mathfrak{R}^m$	- Espaço vetorial de dimensão $m$
$\lambda$	- Envelope espectral
$\beta$	- Vetor de escalonamento ótimo associado a $\lambda$
$\hat{I}_n(\omega)$	- Estimativa do periodograma da matriz $X$
$sm$	- Grau de alisamento
$V_\beta$	- Matriz de covariância do vetor de escalonamento ótimo $\beta$
$\sigma_j$	- Elementos da diagonal principal de $V_\beta$
$\chi_L^2(\alpha)$	- Distribuição chi-quadrada com $L$ graus de liberdade
$\alpha$	- Intervalo de confiança da distribuição chi-quadrada
$A$	- Matriz de mistura do modelo ICA
$S$	- Matriz contendo as componentes independentes
$W$	- Matriz de separação

$DR(j)$	- Taxa de dominância para as componentes independentes
$SL_1$	- Limiar utilizado no método DCT
$SL_2$	- Limiar utilizado no método DCT
$F(x, x_k)$	- Índice de significância utilizado no método DCT
$T_w$	- Tamanho do intervalo de dados
$T_s$	- Tempo de amostragem
$W_G$	- Janela gaussiana
$\alpha_G$	- Parâmetro de ajuste da janela gaussiana
$\mathcal{E}_{SE}$	- Limiar de potência usado no método SE
$\mathcal{E}_{ICA}$	- Limiar de potência usado no método ICA
$t_b$	- Limiar para a quantidade mínima de dados usado no algoritmo SED
ACF	- Função de Autocorrelação
CV	- Coeficiente de Variação
CVE	- Coeficiente de Variação ponderado pela Energia
DCT	- Transformada Discreta de Cosseno
DFT	- Transformada de Fourier Discreta
FFT	- Transformada Rápida de Fourier
IC	- Componentes Independentes
ICA	- Análise de Componentes Independentes
iDCT	- Transformada Discreta de Cosseno Inversa
PCA	- Análise de Componentes Principais
PIMS	- Sistema de Gestão de Informação de Processo
PSD	- Densidade Espectral de Potência
SE	- Envelope Espectral
SED	- Algoritmo de Seleção de Dados

## Sumário

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>16</b>
1.1	Caracterização do Problema e Motivação .....	16
1.2	Objetivos.....	17
1.3	Artigos Publicados em Anais de Eventos.....	18
1.4	Organização do Trabalho .....	18
<b>2</b>	<b>MÉTODOS DE DETECÇÃO DE OSCILAÇÕES.....</b>	<b>19</b>
2.1	Método Baseado na Função de Autocorrelação – ACF .....	19
2.1.1	Cálculo da PSD do Sinal .....	19
2.1.2	Determinação das Bandas de Frequências Dominantes .....	20
2.1.3	Filtragem das Frequências Dominantes.....	21
2.1.4	Cálculo da ACF e Obtenção dos Períodos das Oscilações.....	23
2.1.5	Verificação da Regularidade das Oscilações.....	24
2.1.6	Agrupamento das Oscilações .....	25
2.2	Método Baseado no Envelope Espectral – SE .....	25
2.3	Método Baseado em Análise de Componentes Independentes – ICA .....	28
2.4	Método Baseado na Transformada Discreta de Cosseno – DCT .....	31
<b>3</b>	<b>APLICAÇÃO DOS METODOS .....</b>	<b>39</b>
3.1	Metodologia.....	39
3.1.1	Frequência de corte do filtro de pré-tratamento dos sinais .....	39
3.1.2	Tratamento de Vazamento Espectral.....	40
3.1.3	Parâmetros específicos de cada método .....	42
3.1.3.1	Método ACF .....	42
3.1.3.2	Método DCT.....	43
3.1.3.3	Método SE.....	44
3.1.3.4	Método ICA.....	44
3.1.4	Teste de regularidade das oscilações.....	44
3.1.5	Agrupamento das oscilações .....	46
3.1.6	Variabilidade das oscilações .....	46
3.2	Estudo de Caso .....	48
3.2.1	Aplicação dos Métodos .....	51
3.2.1.1	Método ACF .....	52
3.2.1.2	Método DCT.....	53

3.2.1.3 Método SE .....	54
3.2.1.4 Método ICA .....	55
3.2.2 Aplicação do Teste de Regularidade Sobre as Oscilações Detectadas.....	56
3.2.3 Avaliação da Variabilidade das Oscilações Detectadas .....	56
3.2.4 Avaliação Geral dos Métodos .....	58
<b>4 DETECÇÃO DE OSCILAÇÕES EM SINAIS AFETADOS POR DISTÚRBIOS NÃO OSCILATÓRIOS.....</b>	<b>59</b>
4.1 Problemas com outliers e distúrbios acentuados presentes nos sinais .....	59
4.2 Estudo de Caso .....	64
4.3 Estudo de Caso – Repetibilidade das Análises.....	72
<b>5 CONCLUSÕES .....</b>	<b>82</b>
<b>6 REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>84</b>

# 1 INTRODUÇÃO

## 1.1 Caracterização do Problema e Motivação

Oscilações são comuns em processos industriais e decorrem de problemas tais como má sintonia dos controladores, equipamentos defeituosos, ação de um distúrbio externo, válvulas de controle com agarramento e estratégias de controle inadequadas. Elas podem propagar-se por toda a planta e causar aumento da variabilidade da qualidade do produto final, redução do tempo de vida útil dos equipamentos, redução da produção e até mesmo interrupção da operação da planta (KARRA e KARIM, 2009). Nessa mesma linha, estudos revelaram que malhas com comportamento oscilatório aumentam o preço da produção proporcionalmente à amplitude da oscilação (SHINSKEY, 1990).

Desse modo, detectar a presença de sinais oscilatórios e fazer a correção desse comportamento é uma necessidade atual, que interfere diretamente nos resultados de instalações industriais modernas. Nesse sentido, métodos para detecção de oscilações em malhas de controle industrial foram propostos. Neste trabalho serão usadas quatro técnicas que têm se destacado na literatura: Função de Autocorrelação (*Autocorrelation Function* – ACF), Transformada Discreta de Cosseno (*Discrete Cosine Transform* – DCT), Envelope Espectral (*Spectral Envelope* – SE) e Análise de Componentes Independentes (*Independent Component Analysis* – ICA).

O método baseado na função de autocorrelação foi utilizado por THORNHILL, HUANG e ZHANG (2003) e por KARRA e KARIM (2009), onde a densidade espectral de potência (PSD) foi utilizada heurísticamente para analisar as frequências de oscilação dominantes do sinal e para filtrá-las. A automatização da filtragem para separar as diversas frequências de oscilação do sinal baseou-se na análise do sinal no tempo e no emprego de um algoritmo de agrupamento de frequências próximas. A ACF dos sinais filtrados é obtida a partir da inversa da transformada de Fourier. A aplicação da transformada discreta de cosseno para detecção de oscilações foi proposta em LI, WANG, *et al.* (2010) e aperfeiçoada em WANG, HUANG e LU (2013). A DCT possui a descorrelação e a compactação de energia como características principais para a detecção de oscilações, permitindo que diferentes componentes de frequência presentes no sinal possam ser representadas por poucos coeficientes descorrelacionados. O método baseado no envelope espectral foi proposto por JIANG,



CHOUDHURY e SHAH (2007) e realiza uma combinação linear ótima em um conjunto de sinais, destacando as oscilações e atenuando o ruído. Já a análise por componentes independentes foi empregada por XIA e HOWELL (2005) e é uma extensão da clássica abordagem de análise de componentes principais para identificação dos espectros com padrões semelhantes (THORNHILL, SHAH, *et al.*, 2002).

Entretanto, a aplicação desses métodos de detecção em malhas industriais muitas vezes é dificultada pela presença de *outliers* e distúrbios acentuados nos sinais. A aplicação dos filtros de pré-tratamento, necessários para o bom funcionamento dos algoritmos de detecção de oscilações, sobre sinais com essas características pode resultar na inclusão de uma dinâmica oscilatória de baixa frequência que pode levar a falsas detecções pelos métodos. Com o objetivo de evitar esses problemas ocasionados por filtros aplicados sobre dados com forte presença de *outliers* e distúrbios, será proposta uma metodologia com a finalidade de selecionar apenas segmentos de dados livres de distúrbios não oscilatórios.

## 1.2 Objetivos

Este trabalho está fundamentado nos seguintes objetivos principais:

- Comparar os algoritmos ACF, DCT, SE e ICA a partir de sua aplicação sobre sinais reais de uma planta industrial com múltiplas frequências de oscilação, presença de ruídos e distúrbios, e oscilações de diferentes amplitudes.
- Propor que as oscilações detectadas sejam caracterizadas pelo impacto que potencialmente produzem na variabilidade dos sinais afetados, com o objetivo de orientar as equipes de operação para uma rápida identificação de suas fontes.
- Propor a aplicação de uma metodologia com a finalidade de selecionar dados livres de *outliers* e distúrbios acentuados, que interferem nos resultados obtidos pelos algoritmos de detecção de oscilações.
- Aplicar um dos métodos de detecção de oscilações sobre janelas de dados sequenciais com o objetivo de avaliar a repetibilidade dos resultados obtidos em análises sucessivas.

### 1.3 Artigos Publicados em Anais de Eventos

1. Comparação de métodos para detecção de oscilações em processos industriais, Roberto Vieira Júnior, Celso J. Munaro, Mariana L. Silveira. Aceito para publicação em: XXI Congresso Brasileiro de Automática, Outubro 2016, Vitória, Espírito Santo.

### 1.4 Organização do Trabalho

Este trabalho está dividido em 5 capítulos. No capítulo 2 serão apresentados os quatro métodos de detecção de oscilações utilizados: ACF, DCT, SE e ICA. No Capítulo 3, esses quatro métodos serão comparados a partir de um estudo de caso que utilizará sinais industriais de características distintas. Nesse capítulo será proposta também a caracterização das oscilações detectadas através do impacto que elas potencialmente produzem na variabilidade dos sinais afetados. O capítulo 4 abordará um segundo estudo de caso que contemplará um maior número de sinais de processo pertencentes a um mesmo sistema, os quais serão utilizados para propor a aplicação de uma metodologia com a finalidade de selecionar dados livres de *outliers* e distúrbios acentuados, que interferem nos resultados obtidos pelos algoritmos de detecção de oscilações. Ainda no capítulo 4, um dos métodos de detecção de oscilações será aplicado sobre janelas de dados sequenciais com o objetivo de avaliar a repetibilidade dos resultados obtidos em análises sucessivas. O capítulo 5 apresentará a conclusão para este trabalho.

## 2 MÉTODOS DE DETECÇÃO DE OSCILAÇÕES

Nesta seção serão apresentados os quatro métodos de detecção de oscilações empregados neste trabalho.

### 2.1 Método Baseado na Função de Autocorrelação – ACF

A técnica de detecção de oscilação a partir da função de autocorrelação (*Autocorrelation Function* – ACF), proposta por THORNHILL, HUANG e ZHANG (2003), permite a detecção de múltiplas frequências em um sinal a partir da verificação dos cruzamentos por zero de sua ACF e propõe uma abordagem para testar a regularidade dos períodos das oscilações detectadas. Esse método faz uso de uma importante característica da ACF, que é a sua capacidade de atenuar o ruído presente em sinais de controle industriais e ao mesmo tempo preservar as frequências de oscilação originais do sinal.

Esse método pode ser sumarizado nos seguintes passos:

1. Cálculo da Densidade Espectral de Potência (*Power Spectral Density* – PSD) do sinal;
2. Determinação das bandas de frequências com energia normalizada acima de um limiar pré-estabelecido a partir da PSD calculada;
3. Aplicação de filtros passa-faixa nos sinais de acordo com as faixas de frequências encontradas no passo anterior;
4. Cálculo da ACF dos sinais filtrados e obtenção dos períodos das oscilações a partir das distâncias entre os sucessivos cruzamentos por zero da ACF;
5. Verificação da regularidade das oscilações detectadas;
6. Agrupamento das oscilações detectadas.

Os itens acima apresentados serão detalhados nas próximas seções deste capítulo.

#### 2.1.1 Cálculo da PSD do Sinal

A PSD descreve como a energia de um sinal é distribuída no domínio da frequência. Neste trabalho, a PSD será calculada a partir da Transformada Rápida de Fourier (FFT – *Fast Fourier Transform*), que será aplicada sobre o sinal autocorrelacionado, o que minimiza o efeito do ruído no espectro. A PSD pode ser descrita matematicamente por  $\Phi_x(f)$ :

$$\Phi_x(f) = \sum_{k=1}^N r_{xx}(k) e^{-j2\pi fk} \quad (2.1)$$

onde  $f$  é a frequência,  $N$  é o número de atrasos de  $r_{xx}(k)$ , e  $r_{xx}(k)$  é a autocorrelação do sinal, descrita matematicamente por:

$$r_{xx}(k) = \frac{\sum_{t=1}^{N-k} [x(t) - \bar{x}][x(t+k) - \bar{x}]}{\sum_{t=1}^N [x(t) - \bar{x}]^2} \quad (2.2)$$

onde  $\bar{x}$  é o valor médio para as  $N$  amostras e  $k$  é o atraso.

No método ACF a análise do espectro é realizada a partir da PSD normalizada:

$$\Phi_{Nx}(f) = \frac{\Phi_x(f)}{\sum \Phi_x(f)} \quad (2.3)$$

Conforme será visto a seguir, o espectro  $\Phi_x(f)$  é empregado tanto para detectar as frequências dominantes quanto para determinar as faixas de frequência a serem utilizadas para separar as múltiplas frequências de oscilação do sinal.

### 2.1.2 Determinação das Bandas de Frequências Dominantes

As diferentes características do sinal no tempo determinarão a forma e a distribuição das suas frequências em  $\Phi_x(f)$ . Fatores como o número de frequências de oscilação, as amplitudes do sinal oscilatório e a intensidade do ruído determinarão a amplitude dos picos de potência em  $\Phi_x(f)$ .

O método ACF possui dois limiares que são aplicados na PSD do sinal com o objetivo de separar o ruído das frequências dominantes. O primeiro limiar,  $\mathcal{E}_P$ , analisa a potência da PSD, determinando bandas de frequência que sejam relevantes para a análise do comportamento oscilatório do sinal. As frequências inferiores ( $f_L$ ) e superiores ( $f_U$ ) das bandas selecionadas são determinadas pela intersecção de  $\mathcal{E}_P$  com o gráfico de  $\Phi_{Nx}(f)$ . Esse limiar é calculado a partir da média ( $\mu_{psd}$ ) e do desvio padrão ( $\sigma_{psd}$ ) da PSD analisada:

$$\mathcal{E}_P = \overline{\Phi_{Nx}(f)} + m\sigma_{\Phi_{Nx}(f)} \quad (2.4)$$

onde  $\overline{\Phi_{Nx}(f)}$  é a média aritmética de  $\Phi_x(f)$ ,  $\sigma_{\Phi_{Nx}(f)}$  é o desvio padrão de  $\Phi_{Nx}(f)$ , e  $m$  é o número de desvios padrões de  $\Phi_{Nx}(f)$  a ser considerado no cálculo de  $\mathcal{E}_P$ .

O segundo limiar,  $\mathcal{E}_E$ , verifica a energia das bandas selecionadas, descartando aquelas com energia inferior ao limiar. As energias são calculadas como as áreas sob as curvas delimitadas por cada banda (Teorema de Parseval) (KOOPMANS, 1995):

$$Energia = \sum_{f=f_L}^{f_U} \Phi_{Nx}(f) \quad (2.5)$$

onde  $f_L$  e  $f_U$  denotam as frequências inferiores e superiores, respectivamente, selecionadas em  $\Phi_{Nx}(f)$ .

Baixos valores de energia indicam que o sinal não possui atividade oscilatória significativa na banda selecionada, ou seja, o comportamento oscilatório do sinal é dominante para outras frequências.

Para exemplificar a obtenção das bandas de frequências dominantes, a Figura 2.1 apresenta uma PSD com dois picos de frequências localizados em 0,5rad/s e 2rad/s. A banda de frequência correspondente ao pico de maior frequência é seccionada por  $\mathcal{E}_P$  em  $f_1$  e  $f_2$ , tendo energia suficiente para ser considerada no estudo do comportamento oscilatório do sinal. Já a banda de menor frequência, que também é interceptada por  $\mathcal{E}_P$ , será descartada, pois possui baixa energia e será irrelevante no estudo.




Figura 2.1. Seleção das bandas de frequências dominantes.

### 2.1.3 Filtragem das Frequências Dominantes

A propagação do comportamento oscilatório devido ao acoplamento existente entre as diversas malhas de controle existentes em uma planta industrial, dentre outras consequências, pode fazer com que um mesmo sinal apresente mais de uma frequência de oscilação, uma vez

que distúrbios oscilatórios gerados por diferentes causas em pontos distintos da planta podem se propagar para um mesmo ponto. Múltiplas frequências de oscilação introduzem cruzamentos por zero irregulares, dificultando a análise oscilatória do sinal. THORNHILL, HUANG e ZHANG (2003) abordou esse fato e propôs a utilização de filtros passa-faixa para separar as frequências de oscilação e assim permitir detectar devidamente os cruzamentos por zero da autocorrelação do sinal filtrado, na faixa da frequência desejada.

A abordagem proposta consiste na aplicação inicial do algoritmo de detecção de oscilações sobre todo o espectro do sinal e no armazenamento de todos os períodos encontrados. De posse desses períodos, as faixas de frequência dos filtros são definidas de modo que fiquem centralizadas entre cada par de frequência detectado. Feita a filtragem, o algoritmo é novamente aplicado e os eventuais novos períodos detectados são armazenados. Esse processo iterativo é repetido até que novas oscilações deixem de ser detectadas ou até que as bandas dos filtros se tornem muito estreitas.

Nesse sentido, KARRA e KARIM (2009) propôs melhorias nesse método, utilizando a PSD individual de cada sinal para identificar e separar as prováveis frequências de oscilação e definir as faixas de cada filtro, em substituição à metodologia proposta por THORNHILL, HUANG e ZHANG (2003). As bordas desses filtros, os quais serão aplicados em  $\Phi_{N_x}(f)$ , estarão centralizadas entre cada par de bandas de frequência selecionadas por  $\mathcal{E}_P$ . A borda inferior do filtro utilizado para filtrar a menor frequência do sinal deverá estar centralizada entre zero e a menor frequência da banda correspondente a frequência a ser filtrada. De forma similar, a borda superior do filtro utilizado para filtrar a maior frequência do sinal deverá estar centralizada entre a frequência de Nyquist do sinal e a maior frequência da banda correspondente a frequência a ser filtrada. A Figura 2.2 mostra a PSD de um sinal com três frequências de oscilação e o cálculo dos filtros aqui discutidos.




Figura 2.2. Seleção das bandas de frequências dominantes.

Frequências indesejadas podem ser introduzidas no sinal nas proximidades das bordas dos filtros passa-faixa e deverão ser desconsideradas. Falsos resultados, ainda, podem ser obtidos caso a banda do filtro seja muito estreita, pois esse tipo de filtro pode gerar sinais senoidais a partir de sinais puramente ruidosos (THORNHILL, HUANG e ZHANG, 2003), (TECK, KIONG, et al., 2007), (CHOUDHURY, KARIWALA, *et al.*, 2007). Essa última afirmação é verificada pela obtenção da ACF a partir de um filtro passa-faixa de largura  $\Delta f$ , o qual é centralizada em  $\pm f_0$ , e aplicado na PSD, conforme descrito a seguir (THORNHILL, HUANG e ZHANG, 2003):

$$\begin{aligned}
 r_{xx}(k) &= \int_{-\infty}^{+\infty} \Phi_x(f) e^{2\pi i f k} df \\
 &= \left( \int_{-f_0 - \Delta f / 2}^{-f_0 + \Delta f / 2} e^{2\pi i f k} df \right) + \left( \int_{f_0 - \Delta f / 2}^{f_0 + \Delta f / 2} e^{2\pi i f k} df \right) \\
 &= 2 \times \cos(2\pi f_0 k) \times \frac{\text{sen}(2\pi k \Delta f / 2)}{\pi k}
 \end{aligned} \tag{2.6}$$

Para  $\Delta f$  muito estreito considera-se  $r_{xx}(k) \approx 2\Delta f \cos(2\pi f_0 k)$ . Assim, a ACF será oscilatória mesmo que  $\Phi_x(f)$  não indique esse comportamento.

#### 2.1.4 Cálculo da ACF e Obtenção dos Períodos das Oscilações

Após a separação das múltiplas frequências pelos filtros passa-faixa, a função de autocorrelação de cada segmento é obtida a partir da inversa da transformada de Fourier para as faixas de frequências referentes a cada frequência de oscilação do sinal.

De posse das ACFs, os períodos das oscilações detectadas são obtidos a partir dos cruzamentos por zero de suas respectivas autocorrelações. O período de oscilação é o dobro de tempo entre dois cruzamentos por zero do sinal oscilatório e pode ser determinado por:

$$\overline{T_p} = \frac{2}{n} \sum_{i=1}^n \Delta t_i = \frac{2}{n} \sum_{i=1}^n (t_i - t_{i-1}) \quad (2.7)$$

onde  $\overline{T_p}$  é a média do período,  $t_{i-1}$  e  $t_i$  são dois cruzamentos por zero consecutivos do sinal de interesse, e  $n$  é o número de intervalos entre cruzamentos por zero observados.

Para evitar estimativas não confiáveis, é recomendado que o cálculo da média e do desvio padrão dos cruzamentos por zero considerem entre 7 e 10 cruzamentos.

### 2.1.5 Verificação da Regularidade das Oscilações

Oscilação pode ser definida como uma variação periódica que não é completamente descaracterizada pela presença de ruído (HORCH, THORNHILL, *et al.*, 2007). Detectar esta característica em um sinal coletado na indústria nem sempre é uma tarefa simples para um algoritmo computacional, devido aos cruzamentos por zeros irregulares, causados pelo ruído e pelas múltiplas frequências de oscilação. Métodos matemáticos são empregados com esse intuito para fornecer índices que ajudem a classificar um sinal como sendo oscilatório ou não. O índice de regularidade de período,  $r$ , desempenha essa função na análise dos sinais (THORNHILL, HUANG e ZHANG, 2003).

Esse índice utiliza o conceito de desvio padrão para verificar o quão regular são os valores dos períodos calculados, servindo de indicativo para caracterizar a presença de comportamento oscilatório no sinal, sendo calculado por:

$$r = \frac{1}{3} \frac{\overline{T_p}}{\sigma_{T_p}} \quad (2.8)$$

onde  $\overline{T_p}$  é a média dos períodos e  $\sigma_{T_p}$  é o desvio padrão dos períodos. A obtenção de  $r$  utiliza somente os oito primeiros períodos de oscilação calculados, pois a magnitude da função de autocorrelação fica distorcida para atrasos grandes quando o sinal não é perfeitamente oscilatório.



Uma oscilação é considerada regular se o desvio padrão dos períodos é menor que um terço do seu valor médio, ou seja,  $r \geq 1$ . A utilização deste limiar é justificada estatisticamente por THORNHILL, HUANG e ZHANG (2003).

### 2.1.6 Agrupamento das Oscilações

Sinais coletados em um mesmo processo podem apresentar frequências de oscilação de mesmo valor, uma vez que oscilações se propagam pelas malhas de controle. O agrupamento de períodos de oscilação próximos em múltiplas malhas de controle pode ser efetuado se (THORNHILL, HUANG e ZHANG, 2003):

$$\frac{T_{p1} - T_{p2}}{K_{\sigma} \times \max(\sigma_1, \sigma_2)} < 1 \quad (2.9)$$

onde  $T_{p1}$  e  $T_{p2}$  representam os períodos dos sinais,  $\sigma_1$  e  $\sigma_2$  são seus desvios padrões e  $K_{\sigma}$  é um escalar que pode ser usado para incluir em um mesmo grupo períodos com menor desvio padrão, aumentando assim o agrupamento das frequências próximas.

## 2.2 Método Baseado no Envelope Espectral – SE

O segundo método utilizado para detecção de oscilações foi o envelope espectral (*Spectral Envelope* – SE), cujo objetivo é realizar uma combinação linear ótima em um conjunto de sinais, que destaque as oscilações e atenuem os ruídos. Para apresentar o método, seja:

$$x(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} \quad t = 0, \pm 1, \pm 2, \dots \quad (2.10)$$

onde  $x(t)$  é um vetor de uma série temporal multivariável em  $\mathcal{R}_m$ .

Considere  $X$  como uma matriz  $m \times n$ :

$$X = [x(t-1) \quad x(t) \quad x(t+1) \quad \dots \quad x(t+n-2)] \quad (2.11)$$

A matriz de covariância do conjunto de sinais  $X$  é definida como  $V_x$ , enquanto que o espectro cruzado da mesma matriz  $X$  é definido como  $P_x(\omega)$  (COOLEY, LEWIS e WELCH, 1970).

Seja  $g(t, \beta) = \beta^* x(t)$  o escalar resultante de uma combinação linear transformada de  $\mathcal{R}^m$  para  $\mathcal{R}$  pelo vetor de escalonamento ótimo  $\beta$ , onde  $\beta \in \mathbb{C}^{m \times 1}$ . Efetivamente,  $\beta$  provoca uma

combinação linear em  $x(t)$ , que gera  $g(t, \beta)$ , cuja potência espectral é expressa como  $P_g(\omega, \beta) = \beta^* P_x(\omega) \beta$  e cuja variância é dada por  $V_g(\beta) = \beta^* V_x \beta$ . O operador  $*$  representa o conjugado transposto da variável.

O envelope espectral é definido por:

$$\lambda(\omega) = \sup_{\beta \neq 0} \left\{ \frac{P_g(\omega, \beta)}{V_g} \right\} = \sup_{\beta \neq 0} \left\{ \frac{\beta^* P_x(\omega) \beta}{\beta^* V_x \beta} \right\} \quad (2.12)$$

O valor de  $\lambda$  representa o valor supremo da equação para uma dada frequência  $\omega$  com seu respectivo vetor de escalonamento ótimo  $\beta(\omega)$ . O vetor  $\beta(\omega)$  resultante de  $\lambda(\omega)$  é ótimo para a frequência  $\omega$ , e é único para todo  $\omega$ .

O valor de  $\beta(\omega)$  é mais fácil de interpretar quando a variância de  $X$  é unitária, que resulta em  $\beta^* V_x \beta = I$ . Nessa situação,  $\lambda(\omega)$  é o autovalor que satisfaz a equação abaixo e  $\beta(\omega)$  é o autovetor correspondente:

$$|P_x(\omega) - \lambda(\omega) V_x| = 0 \quad (2.13)$$

Quando a variância de  $X$  é unitária, o valor de  $\beta(\omega)$  auxilia a indicar em que malhas estão localizadas as frequências no conjunto de sinais em análise. Cada elemento do vetor de escalonamento ótimo  $\beta(\omega)$  indica a presença da frequência na malha relativa. Então, se um elemento é considerado estatisticamente zero no vetor de escalonamento ótimo  $\beta(\omega)$ , a frequência  $\omega$  não está presente no sinal representado pelo vetor  $\beta(\omega)$ . Além disso, o valor de cada elemento do vetor  $\beta(\omega)$  é uma indicação do peso da contribuição de cada malha para a frequência  $\omega$ .

Se o estimador do espectro cruzado  $\hat{P}_x$ , usado para calcular o envelope espectral, é um estimador consistente e  $\lambda(\omega)$  é um autovalor distinto de  $|\hat{P}_x(\omega) - \lambda(\omega) V_x| = 0$ , então, pode-se dizer que  $v_n[\hat{\beta}(\omega) - \beta(\omega)]$  converge para uma distribuição normal, quando  $n \rightarrow \infty$ , onde o termo  $v_n$  depende do estimador usado.

O periodograma da matriz  $X$  que contém os sinais observados pode ser calculado como:

$$\hat{I}_n(\omega) = \frac{1}{n} \left[ \sum_{t=0}^{n-1} x(t) e^{-2\pi i t \omega} \right] \left[ \sum_{t=0}^{n-1} x(t) e^{-2\pi i t \omega} \right]^*, -1/2 < \omega \leq 1/2 \quad (2.14)$$

Esse periodograma fornece uma estimativa simples de  $P_x(\omega)$ . Entretanto  $\hat{I}_n(\omega)$  é uma função contínua de  $x$ , cuja utilização não é viável. Se  $n$  é um número inteiro de valor alto, a

Transformada Rápida de Fourier fornece o cálculo rápido de  $\hat{I}_n(k/n)$ , para  $k = 1, 2, \dots, [n/2]$ , onde  $[n/2]$  o maior inteiro menor ou igual a  $n/2$ . As frequências  $\omega_k = k/n$ , para  $k = 1, 2, \dots, [n/2]$ , são chamadas de frequências de Fourier. Então,  $\hat{I}_n(\omega_k)$  nessas frequências pode ser estimado como:

$$\hat{I}_n(\omega_k) = \frac{1}{n} \left[ \sum_{t=0}^{n-1} x(t) e^{-2\pi i t \omega_k} \right] \left[ \sum_{t=0}^{n-1} x(t) e^{-2\pi i t \omega_k} \right]^* \quad (2.15)$$

A principal desvantagem de utilizar o periodograma diretamente é a de que ele não é uma estimativa consistente de  $P_x$ , já que o intervalo de confiança da estimativa geralmente é largo (SHUMWAY, 1988). Para superar essa limitação, pode ser usada uma estimativa alisada do periodograma (BRILLINGER, 1981), (HANNAN, 1970). Neste trabalho o alisamento será obtido a partir de uma média móvel simétrica, que é definida na equação abaixo:

$$\hat{P}_x(\omega_k) = \sum_{j=-sm}^{sm} h_j \hat{I}_n(\omega_{k+j}) \quad (2.16)$$

onde  $sm$  é o grau de alisamento, fundamental na obtenção de um envelope espectral adequado, e  $h_j = (sm - |j| + 1) / (sm + 1)^2$ , cuja soma é unitária, ou seja,  $\sum_{j=-sm}^{sm} h_j = 1$ .

Para a média móvel apresentada na equação (2.16), o valor de  $v_n$  é definido na equação abaixo:

$$v_n = \left( \sum_{j=-sm}^{sm} h_j^2 \right)^{1/2} \quad (2.17)$$

Em aplicações industriais típicas,  $sm$  é selecionado como um inteiro igual a 1 ou 2.

A estimativa do envelope espectral passa ser dada por:

$$\left| \hat{P}_x(\omega) - \lambda(\omega) V_x \right| = 0 \quad (2.18)$$

e a matriz de covariância do vetor de escalonamento ótimo,  $\hat{\beta}(\omega)$ , é obtida por:

$$V_{\beta(\omega)} = \frac{1}{\sqrt{v_n}} \lambda_1(\omega) \sum_{j=2}^m \lambda_j(\omega) \left[ \frac{1}{\lambda_1(\omega) - \lambda_j(\omega)} \right]^2 \beta_j(\omega) \beta_j(\omega)^* \quad (2.19)$$

onde  $\lambda_1(\omega) = \lambda(\omega)$ ,  $\lambda_2(\omega)$ , ...,  $\lambda_m(\omega)$  são os autovalores da equação (2.13), ordenados de forma decrescente e  $\beta_1(\omega) = \beta(\omega)$ ,  $\beta_2(\omega)$ , ...,  $\beta_m(\omega)$  são seus autovetores correspondentes.

Portanto para verificar se  $\hat{\beta}_j$  é estatisticamente zero, deve-se comparar  $2|\hat{\beta}_j(\omega)|^2 / \sigma_j(\omega)$  com  $\chi_2^2(\alpha)$ , que é o valor de corte para uma distribuição chi-quadrada com dois graus de liberdade para um intervalo de confiança  $\alpha$ . Os termos  $\sigma_j$  são os elementos da diagonal principal de  $V_{\beta(\omega)}$ , com  $j = 1, \dots, m$ .

Para simplificar, considere  $\tau = 2|\hat{\beta}_j(\omega)|^2 / \sigma_j(\omega)$ . Se  $\tau > \chi_2^2(\alpha)$ , a hipótese nula no intervalo de confiança  $(1 - \alpha)$  é rejeitada, e a série temporal  $j$  oscila na frequência  $\omega$ . Por outro lado, se a hipótese é aceita, ou seja,  $\tau < \chi_2^2(\alpha)$ , então a série temporal  $j$  não tem oscilação na frequência  $\omega$ .

Assim como no método ACF, é necessário definir um limiar para determinar se o valor de  $\lambda(\omega)$  é considerado relevante ou não no envelope espectral. Em JIANG, CHOUDHURY, e SHAH (2007) e MCDOUGALL, STOFFER, e TYLER, (1997) são apresentadas propostas de testes estatísticos para essa seleção. Neste trabalho será adotado um critério similar ao limiar de potência utilizado no método ACF, definido na equação (2.4), ou seja, o limiar será determinado a partir da média e do desvio padrão do envelope do conjunto de sinais.

### 2.3 Método Baseado em Análise de Componentes Independentes – ICA

A Análise de Componentes Independentes é uma técnica estatística utilizada na extração de fontes independentes a partir de dados observados constituídos pela mistura de fontes desconhecidas. É uma extensão da clássica abordagem de análise de componentes principais (PCA). Esse método é aplicável nas situações em que os dados a serem analisados são compostos pelas misturas de componentes independentes. Como exemplo simples dessa situação pode-se citar a captação por microfones de vozes distintas sobrepostas em um mesmo ambiente, em que cada voz é gerada por uma fonte independente e observada de forma misturada.

O objetivo da decomposição efetuada pelo método ICA é encontrar uma representação linear de dados não gaussianos de modo que as componentes sejam estatisticamente independentes, ou tão independentes quanto possível. A aplicação de ICA para detecção de oscilações foi proposta em XIA e HOWELL (2005) e aperfeiçoada em XIA, HOWELL, e THORNHILL (2005).

As componentes independentes podem ser estimadas através da obtenção de vetores que maximizem algum índice de não-gaussianidade, como *kurtosis*, por exemplo (HYVÄRINEN e OJA, 2000). Esse índice é maior para PSDs de senoides puras, tem seu valor reduzido quando outras frequências dominantes são introduzidas e é muito pequeno para PSDs de ruído branco. Desse modo, essa abordagem extrai eficazmente componentes independentes que possuem alto grau de similaridade com PSDs de fontes oscilatórias puras. Nesse sentido, as ICs geralmente contêm picos espectrais diferentes já que um componente contendo um único pico espectral é mais dominante em termos de não-gaussianidade do que uma componente que possui múltiplos picos. A maximização da não-gaussianidade resulta em ICs de picos únicos e bandas estreitas.

O modelo básico do ICA possui a seguinte estrutura:

$$X = A \times S \quad (2.20)$$

onde:

$X = [x_1 \ x_2 \ \dots \ x_m]'$  é a matriz contendo as observações do processo;

$S = [s_1 \ s_2 \ \dots \ s_n]'$  é a matriz contendo as componentes independentes (ICs), não gaussianas;

$A$  é a matriz de mistura contendo os pesos  $a_{ij}$  ( $i=1\dots m, j=1\dots n$ ).

A partir desse modelo, cada observação do processo pode ser decomposta em uma combinação linear de um conjunto de ICs:

$$x_i' = a_{i1}s_1' + a_{i2}s_2' + \dots + a_{in}s_n', \quad i=1\dots m \quad (2.21)$$

O método ICA é um processo iterativo e envolve tanto a estimação da matriz de mistura  $A$  quanto da matriz  $S$  contendo os componentes independentes. A determinação desse modelo é equivalente a encontrar a matriz de separação  $W$  que satisfaz a equação abaixo:

$$\hat{S} = WX = \begin{bmatrix} w_1' \\ w_2' \\ \vdots \\ w_n' \end{bmatrix} X \quad (2.22)$$

onde  $S = [s_1 \ s_2 \ \dots \ s_n]'$  é a estimativa de  $S$ ,  $W$  é a matriz pseudo-inversa de  $A$  e  $w_j$  é o  $j$ -ésimo vetor normalizado de separação.

Uma forma de determinação do modelo é estimar o primeiro vetor de separação  $w_1$  que maximize a não-gaussianidade de  $s_1' = w_1'X$ , e então estimar o segundo vetor de separação

sob o mesmo princípio, e assim por diante. Algoritmos computacionais que realizam ICA são disponibilizados em domínio público. Este trabalho utilizará o algoritmo FastICA, disponibilizado por HURRI, GÄVERT, *et al.* (1998).

No entanto, o método ICA não prevê formas de determinar o número de ICs que devem ser incluídas no modelo para representar de forma satisfatória o conjunto de espectros. Essa restrição pode ser contornada pela utilização de um modelo PCA ( $X=TW'$ ), em que é adotado o número de componentes que são necessárias no modelo para explicar um determinado percentual da variabilidade do espectro (XIA e HOWELL, 2005). De acordo com THORNHILL, SHAH, *et al.* (2002), a condição ou a decisão para o truncamento das componentes principais acontece quando o autovalor associado ao próximo componente principal é maior que a porcentagem da soma do total dos autovalores. Normalmente essa porcentagem situa-se na ordem dos 3 a 5%, dependendo das características dos sinais no domínio do tempo. A matriz  $T$  do modelo de componentes principais é utilizada ainda como valor inicial da matriz de mistura do modelo ICA com o objetivo de maximização do processo de obtenção das ICs (XIA e HOWELL, 2005).

Após a determinação do modelo ICA desejado, é possível ainda determinar índices de significância que indiquem a influência de cada IC sobre um determinado sinal. Sendo assim, um estágio pós-ICA deve ser aplicado de modo que a matriz de mistura permita identificar relações dominantes entre as ICs e as assinaturas espectrais. Para isso, é necessária a aplicação de algumas operações matriciais sobre o modelo.

Inicialmente os sinais (positivo ou negativo) das ICs devem ser manipulados de modo que o pico dominante de cada componente seja positivo, com o objetivo de facilitar a visualização das ICs. Para isso, deve-se obter o sinal do maior valor absoluto para cada uma das  $n$  ICs obtidas, denotado por  $SN_j$  ( $j=1,\dots,n$ ). Feito isso, são realizados os seguintes ajustes nas matrizes  $A$  e  $S$  do modelo:

$$\begin{aligned} B &= A \times \text{diag}(SN_1, SN_2, \dots, SN_n) \\ C &= \text{diag}(SN_1, SN_2, \dots, SN_n) \times S \\ &\quad \downarrow \\ X &= B \times C \end{aligned} \tag{2.23}$$

onde  $\text{diag}(\cdot)$  é uma matriz diagonal  $n \times n$ .

Dando prosseguimento à manipulação matricial, o valor máximo de cada coluna da matriz de mistura é ajustado de modo que seja igual a 1 com o objetivo de criar um índice de

significância para ressaltar a importância de cada elemento da matriz de mistura resultante. O índice igual a 1 representará a influência mais forte de uma IC sobre o sinal, enquanto que um valor menor indicará que a influência é mais fraca. Sendo assim, deve-se obter o elemento com o maior valor absoluto em cada coluna da matriz  $B=[b_1 \ b_2 \ \dots \ b_n]$ :

$$\Delta_j = \|b_j\|_{\infty} \quad (2.24)$$

Feito isso, são realizados os seguintes ajustes nas matrizes  $B$  e  $C$  do modelo obtido anteriormente:

$$\begin{aligned} D &= B \times \text{diag}(\Delta_1^{-1}, \Delta_2^{-1}, \dots, \Delta_n^{-1}) \\ E &= \text{diag}(\Delta_1, \Delta_2, \dots, \Delta_n) \times C \\ &\quad \downarrow \\ X &= D \times E = [d_1, d_2, \dots, d_n] \times \begin{bmatrix} e'_1 \\ e'_2 \\ \vdots \\ e'_n \end{bmatrix} \end{aligned} \quad (2.25)$$

Após os ajustes, a  $j$ -ésima coluna de  $D$  refere-se ao  $j$ -ésimo componente independente  $e'_j$  e o valor  $d_{i,j}$  (índice de significância) representa a influência de  $e'_j$  sobre o espectro de potência da  $i$ -ésima variável de processo observada.

A partir do modelo ICA é possível ainda determinar uma taxa de dominância ( $DR$  – *Dominance Ratio*) para cada uma das ICs obtidas:

$$DR(j) = \frac{\|a_j c'_j\|_{sum}}{\|AC\|_{sum}} = 100 \left\{ \frac{\|a_j c'_j\|_{sum}}{\sum_{j=1}^n (\|a_j c'_j\|_{sum})} \right\} \% \quad (2.26)$$

Quanto maior for o valor de  $DR(j)$  maior é a influência da  $j$ -ésima IC sobre as eventuais perturbações na planta.

## 2.4 Método Baseado na Transformada Discreta de Cosseno – DCT

A Transformada Discreta de Cosseno é uma função bastante empregada em aplicações de processamento de sinais, particularmente na compressão de som e imagem, sendo utilizada nos padrões de compressão MPEG e JPEG, por exemplo.

A aplicação dessa transformada para a detecção de oscilações foi proposta em LI, WANG, *et al.* (2010) e aperfeiçoada em WANG, HUANG e LU (2013). Essa transformada apresenta

como características mais úteis para a detecção de oscilações a descorrelação e a compactação de energia. Essas propriedades permitem que diferentes componentes de frequência presentes em um conjunto de variáveis de processo possam ser representadas por poucos coeficientes DCT descorrelacionados.

A transformada DCT de uma série temporal  $x(nh)$ , com  $n=1,2,\dots,N$ , e com período de amostragem  $h$ , é definida como:

$$y(k) = w(k) \sum_{n=1}^N x(nh) \cos \frac{\pi(2n-1)(k-1)}{2N}, \quad k=1,\dots,N$$

$$w(k) = \begin{cases} \frac{1}{\sqrt{N}}, & k=1 \\ \sqrt{\frac{2}{N}}, & 2 \leq k \leq N \end{cases} \quad (2.27)$$

A transformada DCT inversa (iDCT) é dada por:

$$x(nh) = \sum_{k=1}^N w(k) y(k) \cos \frac{\pi(2n-1)(k-1)}{2N}, \quad n=1,\dots,N \quad (2.28)$$

Após a aplicação da transformada, os componentes associados com diferentes frequências são distribuídos separadamente no domínio da transformada, podendo ser facilmente isolados. Após a isolamento dos segmentos, aplica-se a transformada inversa iDCT sobre eles e verifica-se no domínio do tempo a regularidade dos cruzamentos por zero desses segmentos.

Na prática, o principal obstáculo para isolar esses segmentos é o fato de os sinais industriais serem normalmente contaminados por ruídos. Se o ruído for branco, a DCT é diferente de zero em todas as frequências, dificultando a separação da transformada em segmentos. Com o objetivo de reduzir os efeitos do ruído, é proposta a utilização do limiar definido abaixo:

$$SL_1 = k_l \sigma_{DCT} \quad (2.29)$$

onde  $\sigma_{DCT}$  é o desvio padrão de  $y(k)$  e  $k_l$  é um escalar, cuja escolha deve ser feita a partir da avaliação das transformadas dos sinais monitorados, preservando os segmentos com picos mais significativos e eliminando os efeitos de ruídos (componentes com coeficientes de menores valores). LI, WANG, *et al.* (2010) sugere a utilização de  $k_l=3$ . Entretanto, a experiência do autor com a aplicação prática do método DCT sobre sinais industriais com características de baixa relação sinal-ruído indicou a necessidade de elevar esse escalar para valores próximos a 10, pois a utilização de um valor mais baixo ( $k_l=3$ ) fez com que os



segmentos ficassem mais alargados e com uma pequena distância de separação entre segmentos consecutivos, dificultando a separação.

A partir do limiar  $SL_l$ , obtém-se a sequência  $y_f(k)$  abaixo:

$$y_f(k) = \begin{cases} y(k), & |y(k)| \geq SL_l \\ 0, & |y(k)| < SL_l \end{cases} \quad (2.30)$$

Se  $SL_l$  for bem selecionado,  $y_f(k)$  preserva os componentes mais significativos de  $y(k)$  e remove os principais efeitos do ruído branco presente no sinal e os segmentos contendo diferentes componentes de frequência de  $x(nh)$  poderão ser obtidos de forma separada a partir de  $y_f(k)$ . O ponto inicial  $k_{s,i}$  e o ponto final  $k_{e,i}$  do  $i$ -ésimo segmento de  $y_f(k)$ , denominado como  $y_{f,i}(k)$ , são determinados pelas seguintes condições:

$$\begin{cases} y_f(k_{s,i}) \neq 0 \text{ e } y_f(k_{s,i} - r) = 0, \text{ para } r = 1 \\ y_f(k_{e,i}) \neq 0 \text{ e } y_f(k_{e,i} - r) = 0, \text{ para } r = 1, 2, 3, 4 \\ k_{s,i} \leq k_{e,i} \end{cases} \quad (2.31)$$

A definição desses pontos foi determinada com base na DCT de um sinal senoidal do tipo  $x(nh) = \text{sen}(2\pi\omega nh + \phi)$ , que usualmente possui o padrão  $y(k) = \dots, 0, *, \dots, *, 0, \dots$ , em que o \* indica a presença de elementos de valor diferente de zero. Em alguns casos especiais a DCT de um sinal senoidal pode ter o padrão  $y(k) = \dots, 0, *, 0, *, 0, \dots$ . Esse último padrão especial implica na necessidade de que o ponto final  $k_{e,i}$  deve ser determinado pela busca de dois zeros consecutivos ao invés de um único zero. Com o objetivo de tornar o método mais robusto contra ruídos é requerida a obtenção de quatro zeros consecutivos para localizar o ponto final  $k_{e,i}$  (LI, WANG, *et al.*, 2010).

Os segmentos isolados devem ser retornados para o domínio do tempo através da iDCT e sua regularidade deve ser verificada a partir da verificação dos cruzamentos por zero. Para isso, inicialmente devem ser obtidas as sequências  $y_i(k)$  com o seguinte formato:

$$y_i(k) = \begin{cases} y_{f,i}(k), & \text{para } k_{s,i} \leq k \leq k_{e,i} \\ 0, & \text{para os demais valores de } k \end{cases} \quad (2.32)$$

De posse de  $y_i(k)$ , devem ser aplicadas as iDCTs para a obtenção de suas contrapartes no domínio do tempo, denominadas  $x_i(nh)$ .

O próximo passo consiste na obtenção das posições dos cruzamentos por zero,  $Z_i(l)$ , de cada  $x_i(nh)$  para  $l=1, 2, \dots, L$ , onde  $L$  é o número total de cruzamentos por zero:

$$T_i(l) = 2[Z_i(l) - Z_i(l-1)], \quad l = 2, 3, \dots, L \quad (2.33)$$

Devem ser calculados os valores do período médio e do desvio padrão de  $T_i(l)$  para a verificação da regularidade da possível oscilação detectada. De forma similar à abordagem empregada no método ACF, uma oscilação pode ser considerada regular se o desvio padrão dos períodos é menor que um terço do seu valor médio, ou seja:

$$r = \frac{1}{3} \frac{\overline{T_p}}{\sigma_{T_p}} \geq 1 \quad (2.34)$$

onde  $\overline{T_p}$  é a média dos períodos e  $\sigma_{T_p}$  é o desvio padrão dos períodos. Para evitar estimativas não confiáveis, é recomendado a utilização de no mínimo oito cruzamentos por zero para o cálculo da média e do desvio padrão do período. Maiores detalhes a respeito dessa verificação serão apresentados na seção 3.1.4.

Caso ruídos coloridos estejam presentes no sinal, existe a possibilidade de que alguns de seus componentes ultrapassem o limiar  $SL_1$ , enquanto que a maioria será zerada. Nessa situação, a iDCT do segmento isolado correspondente ao ruído não se assemelhará ao ruído colorido original e será similar a uma componente oscilatória, podendo levar a falsas detecções. A solução para esse problema consiste na utilização de um segundo limiar  $SL_2$  de valor mais baixo que  $SL_1$  (LI, WANG, *et al.*, 2010):

$$SL_2 = k_2 \sigma_{DCT} \quad (2.35)$$

Para a aplicação do novo limiar  $SL_2$ , deve-se obter o máximo absoluto de cada segmento  $y_i(k)$  obtido a partir do limiar  $SL_1$  que tenha passado no teste de regularidade:

$$y_{i,\max} = \max_k (|y_i(k)|) \quad (2.36)$$

Após a aplicação do limiar  $SL_2$ , devem ser selecionados apenas os segmentos que possuem o mesmo valor máximo absoluto  $y_{i,\max}$  que os segmentos obtidos pela utilização de  $SL_1$ . Os segmentos resultantes são denominados como  $y_{j,j}(k)$  para  $j=1, 2, \dots, J$  e as sequências obtidas após a separação dos segmentos são denotadas por  $y_j(k)$ .

As sequências  $y_j(k)$  são retornadas para o domínio do tempo a partir da iDCT e transformadas em  $x_j(nh)$ , que devem ter sua regularidade avaliada a partir de seus cruzamentos por zero. Se  $x_i(nh)$  e  $x_j(nh)$  (segmentos obtidos a partir dos limiares  $SL_1$  e  $SL_2$ , respectivamente) satisfizerem o teste de regularidade, o segmento é considerado como uma oscilação.

O segundo limiar deve ser escolhido com o objetivo de preservar um maior número de coeficientes em torno dos maiores picos, mas mantendo a separação entre os diferentes segmentos definidos pelo primeiro limiar. LI, WANG, *et al.* (2010) sugere a utilização de  $k_2=1$ , mas, no entanto, a experiência do autor com a aplicação prática do método DCT sobre sinais industriais bastante corrompidos por ruídos indicou a necessidade de elevar esse escalar para valores próximos a 7. A utilização de um baixo valor para  $k_2$  fez com que vários segmentos selecionados pelo limiar  $SL_1$  fossem unidos, formando “super segmentos”, e tendo como resultado a obtenção de sinais não regulares no domínio do tempo, mesmo em situações em que a PSD do sinal original indicava claramente a presença de um distúrbio oscilatório.

WANG, HUANG e LU (2013) introduziu um índice de significância que indica a influência de um determinado componente oscilatório sobre as eventuais perturbações presentes na planta. Para a determinação desse índice, seja  $x_k(nh)$  a  $k$ -ésima componente oscilatória da série temporal  $x(nh)$ , para  $k=1,2,\dots,K$ . O índice de significância  $F(x,x_k)$  pode ser definido da seguinte forma:

$$F(x,x_k) = 100 \left( 1 - \frac{\|x_k(nh) - x(nh)\|_2}{\|x_k(nh) - E\{x(nh)\}\|_2} \right) \quad (2.37)$$

onde  $\|\bullet\|_2$  representa a norma Euclidiana. Esse índice é extensivamente empregado no campo de identificação de sistemas para medir a qualidade dos modelos identificados (LJUNG, 2010). Fisicamente,  $F(x,x_k)$  mede o percentual de energia de  $x(n)$  explicado por  $x_k(n)$ . Quanto maior for o valor de  $F(x,x_k)$  maior é a influência do componente  $x_k(n)$  sobre as eventuais perturbações na planta.

Com o objetivo de ilustrar o funcionamento do algoritmo, seja o sinal abaixo formado pela composição de duas senoides de frequências de oscilação distintas associadas a uma tendência de variação lenta e a um ruído branco  $v(nh)$ :

$$x_1(nh) = 3\text{sen}(0,2 \times 2\pi nh) + 2\text{sen}(2\pi nh) + 0,005n^2 + v(nh) \quad (2.38)$$

onde o período de amostragem é  $h=0,1s$  e  $v(nh)$  é um ruído branco gaussiano de média zero e variância  $\sigma_v^2=1,3$ .

A Figura 2.3 apresenta esse sinal no tempo e a sua respectiva DCT.

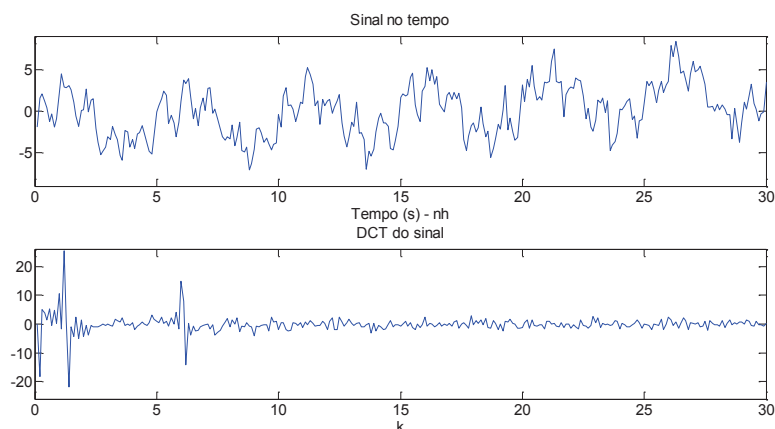


Figura 2.3. Sinal  $x_I(nh)$  no tempo (superior) e DCT desse sinal (inferior).

Após a aplicação do primeiro limiar,  $SL_I$ , três componentes foram separadas pelo algoritmo, conforme Figura 2.4. Essa mesma figura traz também essas três componentes retornadas para o domínio do tempo após a aplicação da iDCT.




Figura 2.4. DCT do sinal  $x_I(nh)$  após a aplicação do limiar  $SL_I$  e as três componentes seleccionadas no domínio do tempo.

A Tabela 2.1 apresenta os períodos médios e os desvios padrão de cada uma das três componentes obtidos após a verificação dos cruzamentos por zero. A partir dessa tabela é possível perceber que apenas dois segmentos apresentaram regularidade.

Tabela 2.1. Resultados obtidos após a aplicação do limiar  $SL_1$ .

Componente	Período Médio (s)	Desvio Padrão (s)	Índice de Regularidade
1	Inf	-	-
2	5,2000	0,4000	4.3333
3	1,0000	0,0525	6.3465

Dando seguimento à aplicação do método, foi aplicado o limiar  $SL_2$  sobre a DCT do sinal, conforme Figura 2.5. A aplicação desse segundo limiar resultou na seleção de seis segmentos. Entretanto, apenas os dois segmentos que contém o mesmo máximo apresentado pelos segmentos selecionados por  $SL_1$  serão avaliados. A iDCT desses dois segmentos também é mostrada na Figura 2.5.




Figura 2.5. DCT do sinal  $x_1(nh)$  após a aplicação do limiar  $SL_2$  e as duas componentes selecionadas no domínio do tempo.

A Tabela 2.2 apresenta os períodos médios e os desvios padrão dos dois componentes avaliados após a aplicação do segundo limiar, de onde se verifica que os dois novos segmentos apresentaram regularidade. Desse modo, o algoritmo baseado na DCT detectou duas oscilações no sinal  $x_I(nh)$ , com períodos aproximados de 1 e 5 segundos.

Tabela 2.2. Resultados obtidos após a aplicação do limiar  $SL_2$ .

<b>Componente</b>	<b>Período Médio (s)</b>	<b>Desvio Padrão (s)</b>	<b>Índice de Regularidade</b>
1	4,9273	1.4402	1,1404
2	1,0000	0,0525	6.3465

O índice de significância  $F(x, x_k)$  obtido para as duas detecções efetuadas pelo método foi igual a 27,02 para a oscilação de período 5 segundos e de 9,53 para a oscilação de período 1 segundo.

### 3 APLICAÇÃO DOS METODOS

Neste capítulo, os quatro métodos de detecção de oscilações foram aplicados sobre oito sinais provenientes de uma Plataforma *Offshore* de Produção de Óleo e Gás. Foram selecionados sinais com características oscilatórias, incluindo frequências distintas sobrepostas (sinais 1 a 4), sinais corrompidos por distúrbios (sinais 5 e 6) e sinais com presença de oscilações de pequena amplitude (sinais 7 e 8), visando avaliar o comportamento dos quatro métodos nessas condições. Tal análise foi realizada de acordo com a metodologia que será descrita a seguir.

Os algoritmos computacionais utilizados para a aplicação dos métodos foram desenvolvidos em Matlab, utilizando um computador com processador Intel Core i3 de 2,4 GHz, com 4Gb de memória RAM, sob o sistema operacional Windows 10. Os tempos de execução obtidos para cada algoritmo após sua aplicação sobre os oito sinais de processo indicados acima, incluindo a geração dos gráficos que serão apresentados nas seções 3.2.1.1 a 3.2.1.4, são mostrados na Tabela 3.1.

Tabela 3.1. Tempo de execução dos algoritmos.

Método	Tempo de Execução (segundos)
ACF	1,2704
DCT	1,5180
SE	7,7615
ICA	2,1342

#### 3.1 Metodologia

Apresenta-se aqui a metodologia utilizada para configuração de parâmetros dos quatro métodos utilizados, bem como as modificações efetuadas nos algoritmos.

##### 3.1.1 Frequência de corte do filtro de pré-tratamento dos sinais

Os sinais coletados em plantas industriais estão sujeitos à influência de ruídos e perturbações que podem inviabilizar a detecção de seu comportamento oscilatório. Interferências de campo magnético, mudanças de *setpoint*, instrumentos com má qualidade de transmissão ou mal dimensionados e até mesmo a própria dinâmica do processo podem introduzir componentes não estacionárias no sinal, que afetam os resultados dos algoritmos de

detecção de oscilação. Por isso, antes da aplicação dos métodos, um filtro passa faixa é utilizado com o objetivo de eliminar tendências, *outliers*, nível DC, comportamento transitório e ruídos em altas frequências.

O limiar superior desse filtro é escolhido com o objetivo de eliminar frequências de oscilação que estejam muito próximas da frequência de Nyquist do sinal (1 Hz/Hz), o que ocasiona ruídos de alta frequência, sendo usado o limiar de 0,99Hz/Hz proposto em KARRA e KARIM (2009).

Já a escolha da frequência de corte inferior do filtro é feita avaliando os espectros dos sinais a serem monitorados, de modo a filtrar o espectro de baixa frequência associado a distúrbios, caracterizados por bandas largas de frequência. O valor mínimo recomendado para esse limiar inferior ( $f_l$ ) deve levar em consideração o fato de que a avaliação das regularidades dos períodos detectados utiliza um mínimo de oito cruzamentos por zero (oito semi-períodos) para evitar estimativas não confiáveis. Sendo assim, a máxima oscilação detectável pelos algoritmos será equivalente a um quarto do tamanho do intervalo de dados, já que será necessária a presença de um mínimo de quatro períodos completos da oscilação no intervalo. Logo, o valor mínimo de  $f_l$  é de  $4/T_w$  Hz, em que  $T_w$  é o tamanho do intervalo de dados.

Normalizando  $f_l$ , tem-se que:

$$f_l = \frac{4/T_w}{1/2T_s} = 8 \frac{T_s}{T_w} \text{ Hz / Hz} \quad (3.1)$$

onde  $T_s$  é o tempo de amostragem do sinal e  $1/2T_s$  é a frequência de Nyquist.

### 3.1.2 Tratamento de Vazamento Espectral

Um grande número de frequências pode ser detectado quando o vazamento espectral está presente. Esse fenômeno ocasiona o surgimento de múltiplos picos próximos para uma única frequência original do sinal e pode dificultar a caracterização de oscilações que possuam pouca energia, quando múltiplas frequências estão presentes no sinal.

O resultado da transformada de Fourier para um sinal oscilatório amostrado com número de períodos inteiros é dado por um único pico de potência no espectro do sinal, pois a média do resultado da multiplicação entre o sinal original e a frequência fundamental, ou suas harmônicas, que não correspondem a frequência de oscilação do sinal será zero. Entretanto a aplicação de uma janela inadequada ao sinal amostrado pode selecionar números não inteiros



de períodos de oscilação afetando a relação descrita. Nesse caso a frequência de oscilação original do sinal é distorcida e uma descontinuidade é introduzida através da convolução entre os dados truncados e a função impulso utilizada na Transformada de Fourier Discreta (DFT). Quanto maior for a descontinuidade maior será o efeito do vazamento espectral.

A Figura 3.1-I mostra um sinal coletado com período de amostragem  $T_s$  e frequência  $1/T_1$ , enquanto que a Figura 3.1-II exibe uma janela retangular de tamanho  $T_o$  utilizada pela DFT para truncamento dos dados coletados e a Figura 3.1-III o resultado desse truncamento. O resultado da convolução entre a Figura 3.1-III e a Figura 3.1-IV é apresentado na Figura 3.1-V, onde é possível identificar o aparecimento de descontinuidades em  $T_o$ , que ocasionará o vazamento espectral.




Figura 3.1. Passos da DFT utilizando janela retangular para truncamento dos dados.

Garantir um intervalo de dados com número inteiro de período é inexecutável quando a frequência de oscilação do sinal não é previamente conhecida. Adicionalmente, sinais com múltiplas frequências de oscilações podem não apresentar número inteiro de períodos concomitantemente. Para mitigar esse problema utiliza-se uma estimativa suavizada da PSD obtida a partir de uma janela espectral ponderada consistente (UITERT, 1978). As janelas de Hamming e de Gauss são as que mostraram melhores resultados para os dados utilizados. A janela gaussiana ( $W_G$ ), adicionalmente, permite ajustar o efeito desse tratamento a partir do parâmetro  $\alpha_G$ :

$$W_g = e^{-\frac{1}{2}\left(\alpha_G \frac{n}{L/2}\right)^2} \quad (3.2)$$

onde  $-N/2 \leq n \leq N/2$ ,  $\alpha_G \geq 2$ , sendo o tamanho da janela  $L = N - 1$ .

A fim de evitar o vazamento espectral, a PSD calculada para o sinal deve ser multiplicada por uma janela  $W_G$ . O aumento de  $\alpha_G$  melhora o vazamento espectral, porém atenua a energia de oscilação, de modo que sua escolha deve ser feita a partir da avaliação dos espectros dos sinais a serem monitorados, objetivando a eliminação dos múltiplos picos espectrais próximos sem atenuar de forma excessiva os picos presentes na PSD.

A Figura 3.2 permite verificar a funcionalidade da utilização da janela gaussiana com  $\alpha_G=7$  para minimizar o efeito do vazamento espectral em relação ao espectro do mesmo sinal obtido a partir de uma janela retangular.

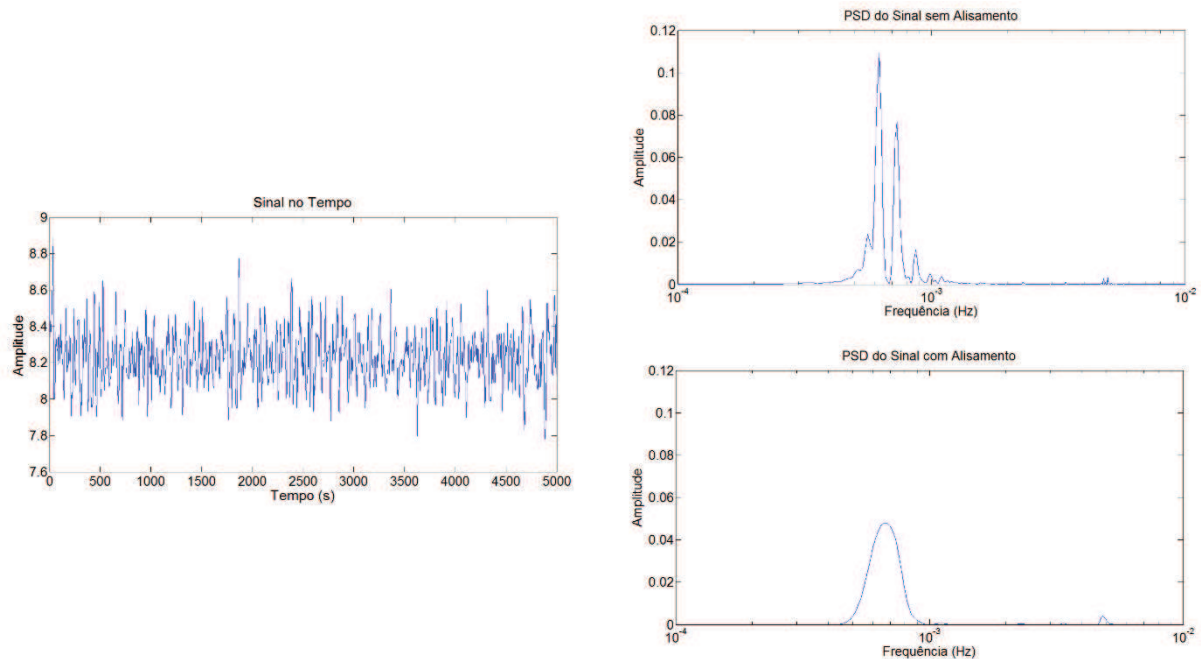


Figura 3.2. Espectro de um sinal de características oscilatórias com e sem a aplicação de uma janela de Gauss.

### 3.1.3 Parâmetros específicos de cada método

#### 3.1.3.1 Método ACF

O método ACF tem dois limiares que são aplicados na PSD do sinal com o objetivo de separar o ruído das frequências dominantes. O primeiro limiar,  $\mathcal{E}_p$ , analisa a potência da PSD, determinando bandas de frequência que sejam relevantes para a análise do comportamento oscilatório do sinal. As frequências inferiores ( $f_L$ ) e superiores ( $f_U$ ) das bandas selecionadas

são determinadas pela intersecção de  $\mathcal{E}_p$  com o gráfico da PSD do sinal. Esse limiar é calculado a partir da média ( $\mu_{PSD}$ ) e do desvio padrão ( $\sigma_{PSD}$ ) da PSD analisada.

O segundo limiar verifica a energia das bandas de frequências selecionadas, descartando aquelas com energia inferior ao limiar. As energias são calculadas como as áreas sob as curvas delimitadas por cada banda.

### 3.1.3.2 Método DCT

O método DCT adota dois limiares com o objetivo de minimizar os efeitos indesejados de ruídos presentes no sinal, já que picos na transformada ocasionados por ruídos podem levar a falsas detecções. Inicialmente, utiliza-se um limiar mais alto calculado a partir do desvio padrão ( $\sigma_{DCT}$ ) da DCT do sinal, para separar a transformada em diversos segmentos. Esses segmentos são levados de volta para o domínio do tempo e são avaliados por um teste de regularidade do período de oscilação. Aqueles que passarem no teste são considerados como possíveis candidatos a oscilações. A utilização de um limiar mais alto se faz necessária para evitar que segmentos muito estreitos sejam selecionados de forma automática pelo algoritmo (segmentos estreitos geram uma senoide quase perfeita após a aplicação da DCT inversa sobre eles, ocasionando falsas detecções).

Em um segundo passo, utiliza-se um novo limiar, de valor mais baixo, também calculado a partir de  $\sigma_{DCT}$ , com o objetivo de descartar eventuais falsas detecções ocasionadas por ruídos ou outros distúrbios. Esse limiar aumenta a largura do segmento, fazendo com que componentes originadas de ruídos que tenham sido descartadas anteriormente (e que fizeram com que o segmento passasse no teste de regularidade) sejam incluídas e avaliadas em um novo teste.

A escolha do primeiro limiar deve ser feita a partir da avaliação das transformadas dos sinais monitorados, preservando os segmentos com picos mais significativos e eliminando os efeitos de ruídos (componentes com coeficientes de menores valores). O segundo limiar deve ser escolhido com o objetivo de preservar um maior número de coeficientes em torno dos maiores picos, mas mantendo a separação entre os diferentes segmentos definidos pelo primeiro limiar.

### 3.1.3.3 Método SE

O método SE possui um limiar similar ao parâmetro  $\mathcal{E}_p$ , utilizado no ACF, que tem o objetivo de descartar pequenos picos associados a componentes ruidosas no gráfico com o envelope espectral do conjunto de sinais. Como os picos de frequências no envelope decorrentes da atividade oscilatória são afastados da média da distribuição estatística do envelope, o valor desse limiar é determinado a partir da média e do desvio padrão do envelope:

$$\mathcal{E}_{SE} = \mu_{SE} + m\sigma_{SE} \quad (3.3)$$

onde  $m$  é um escalar e  $\mu_{SE}$  e  $\sigma_{SE}$  são a média e o desvio padrão do envelope.

A escolha do valor de  $m$  deve ser feita a partir da avaliação do envelope dos sinais, preservando frequências que sejam relevantes para a análise do comportamento oscilatório dos sinais.

### 3.1.3.4 Método ICA

Após a decomposição do sinal em componentes independentes (ICs), deve ser avaliado se as ICs obtidas correspondem a uma componente oscilatória ou a um sinal ruidoso. Essa avaliação é efetuada a partir da quantidade de picos que ultrapassam um limiar calculado a partir da média ( $\mu_{ic}$ ) e do desvio padrão ( $\sigma_{ic}$ ) da IC analisada e da energia desses picos.

Outra configuração a ser ajustada é o número de componentes independentes que devem ser incluídas no modelo para representar de forma satisfatória o conjunto de espectros. Esse ajuste é efetuado de forma indireta a partir da escolha do percentual da variabilidade do espectro que pode ser explicado por um modelo de componentes principais (PCA), onde o número de ICs será a quantidade de componentes principais necessárias. Um valor muito baixo desse percentual pode resultar no descarte indesejado de componentes que possuam características oscilatórias. Por outro lado, um valor muito alto pode fazer com que componentes de representatividade muito baixa no conjunto de espectros sejam incluídas no modelo, aumentando de forma desnecessária o conjunto de componentes a serem analisados.

### 3.1.4 Teste de regularidade das oscilações

Uma vez detectadas as frequências de oscilação, deve-se avaliar se os correspondentes sinais no tempo apresentam regularidade dos períodos, verificando os cruzamentos por zero.

O método ACF utiliza como indicador o índice de regularidade de períodos (THORNHILL, HUANG e ZHANG, 2003), que considera o período regular caso seu valor médio seja superior a três vezes o seu desvio padrão, utilizando para isso os oito primeiros períodos calculados.

Para o método DCT, LI, WANG, *et al.* (2010) também propõe a utilização do índice de regularidade dos períodos, enquanto que WANG, HUANG e LU (2013) apresenta uma evolução para esse índice, baseada no coeficiente de variação ( $CV$ ) definido abaixo:

$$CV = \frac{\sigma_{T_p}}{\bar{T}_p} \quad (3.4)$$

onde  $\bar{T}_p$  é a média dos períodos e  $\sigma_{T_p}$  é o desvio padrão dos períodos.

Esse coeficiente mede a dispersão da distribuição de probabilidade do sinal, ou mais especificamente a variabilidade relativa à média. GULHAR, KIBRIA, *et al.*, (2012) avaliou de forma empírica a distribuição do  $CV$  e propôs o seguinte intervalo de confiança:

$$\frac{\hat{CV} \sqrt{L-1}}{\sqrt{\chi_{L-1,1-\alpha/2}^2}} < CV < \frac{\hat{CV} \sqrt{L-1}}{\sqrt{\chi_{L-1,\alpha/2}^2}} \quad (3.5)$$

onde  $\hat{CV} = \sigma_T / \mu_T$ ,  $\mu_T$  e  $\sigma_T$  são as estimativas da média e do desvio padrão do sinal,  $L$  é o tamanho da amostra,  $\alpha$  está associado ao intervalo de confiança ( $\alpha=0,05$ , por exemplo) e  $\chi_{L-1,\alpha/2}^2$  é a  $100\alpha/2$  percentagem de uma distribuição chi-quadrada com  $L-1$  graus de liberdade. O teste revisado tem a seguinte forma:

$$R_{T,\alpha} := \frac{\sqrt{\chi_{L-1,\alpha/2}^2}}{\sigma_T / \mu_T \sqrt{L-1}} > 3 \quad (3.6)$$

Os métodos SE e ICA não foram propostos originalmente com mecanismos para verificação da regularidade das oscilações detectadas, pois ambos processam as informações de todos os sinais avaliados de forma conjunta, não sendo efetuada uma análise individual de cada sinal. Desse modo, após a aplicação dos métodos SE ou ICA e de posse das oscilações identificadas em cada sinal, é proposta aqui a utilização de um método de verificação de regularidade que utilize como base a PSD individual de cada sinal. As bordas dos filtros passa faixa que serão utilizados para separar as frequências dominantes presentes no sinal são definidas de modo que fiquem centralizadas entre cada par de bandas de frequência selecionadas por um limiar calculado a partir da média e do desvio padrão da PSD individual.

Para esses dois últimos métodos, foi avaliada também a possibilidade de utilização do envelope espectral e das respectivas componentes independentes para definição do limiar e das bordas dos filtros. No entanto, essa abordagem resultou em filtros com larguras de faixa mais amplas, que resultaram no descarte indevido de oscilações cuja regularidade havia sido comprovada por outros métodos. Tal característica ocorre porque o envelope e as ICs possuem características do conjunto total de sinais, cujos gráficos representando as características espectrais apresentam picos com uma base mais alargada que no caso das PSD individuais.

### 3.1.5 Agrupamento das oscilações

Como as oscilações se propagam pelas malhas próximas e podem ser detectadas com frequências ligeiramente diferentes, seu agrupamento se faz necessário. Dois períodos podem ser agrupados se (THORNHILL, HUANG e ZHANG, 2003):

$$\frac{T_{p1} - T_{p2}}{K_{\sigma} \times \max(\sigma_1, \sigma_2)} < 1 \quad (3.7)$$

onde  $T_{p1}$  e  $T_{p2}$  representam os períodos dos sinais e  $\sigma_1$  e  $\sigma_2$  são seus desvios padrões. O agrupamento das frequências pode ser controlado através da multiplicação do desvio padrão por um escalar ( $K_{\sigma}$ ), podendo ser incluídas em um mesmo grupo períodos com menor desvio padrão, aumentando assim o agrupamento das frequências próximas.

### 3.1.6 Variabilidade das oscilações

Oscilações que apresentem baixa variabilidade (pequena amplitude) tendem a não trazer muitos transtornos para a operação da planta e por isso a sua detecção e exibição não são de interesse do pessoal de operação, sendo proposta a aplicação de um limiar seletivo para avaliação da variabilidade das oscilações identificadas.

É proposto aqui que a verificação da variabilidade do sinal seja efetuada a partir de seu Coeficiente de Variação (CV), expresso pela relação desvio padrão/média, e que é usado para analisar a dispersão do sinal em torno de seu valor médio. O CV é uma forma de expressar a variabilidade dos dados excluindo a influência da ordem de grandeza e da unidade de medida da variável, o que possibilita sua aplicação em dados industriais onde os diversos sinais

disponíveis para o sistema de controle são de naturezas diferentes (variáveis de pressão, nível, vazão, etc.).

Entretanto, o CV representa a variabilidade total presente no sinal e não apenas a variabilidade causada pelas oscilações detectadas. Além disso, nos casos em que mais de uma oscilação esteja presente em um mesmo sinal, é importante que a análise da variabilidade seja efetuada de forma separada para cada frequência de oscilação. Para isso, é proposto que o CV seja ponderado pela energia relativa às bandas de frequência relacionadas a cada componente oscilatória identificada na PSD do sinal. As energias são calculadas como as áreas sob as curvas delimitadas por cada banda de frequência nos gráficos com as PSDs normalizadas e expressam um percentual do quanto cada oscilação contribui com a energia oscilatória total presente no sinal. Logo, a variabilidade ocasionada por cada oscilação no sinal é calculada como o produto entre o CV do sinal e a energia da respectiva oscilação, resultando no CVE, que é o CV ponderado pela energia:

$$CVE = CV \times Energia \quad (3.8)$$

Para exemplificar o cálculo do CVE, a Figura 3.3 apresenta a PSD normalizada de um sinal onde foram efetuadas duas detecções de oscilações com períodos de aproximadamente 204 e 433 segundos, com energias normalizadas de 70,02% e 10,46%, respectivamente. O sinal em questão possui CV=0,0170 e os respectivos CVEs para cada oscilação são iguais a:

$$\begin{aligned} CVE_1 &= 0,0170 \times 70,02\% = 0,0119 \\ CVE_2 &= 0,0170 \times 10,46\% = 0,0018 \end{aligned} \quad (3.9)$$

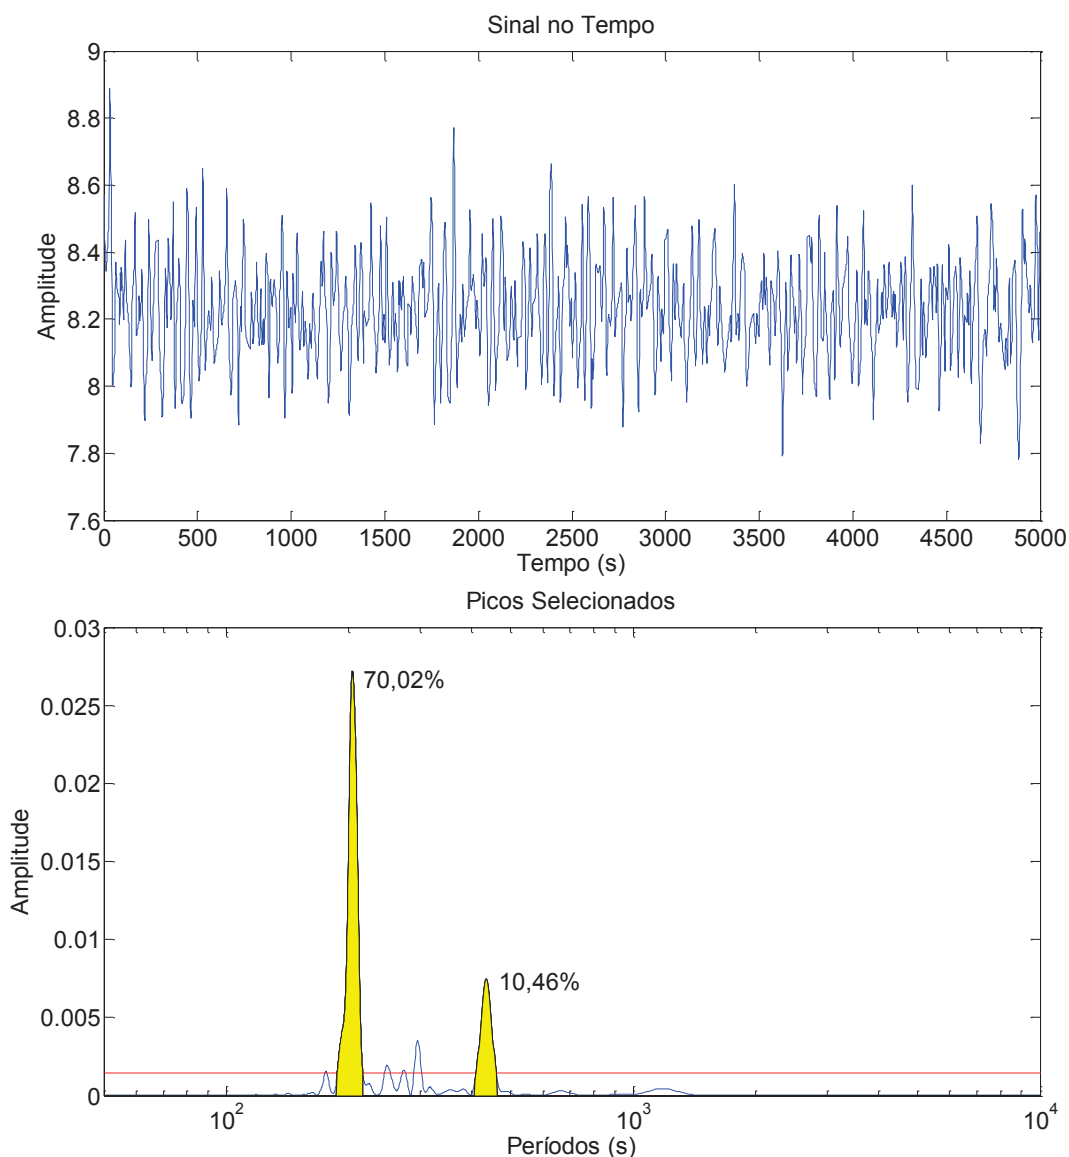


Figura 3.3. Exemplo de cálculo do CVE como indicativo da variabilidade de cada oscilação detectada.

Com o objetivo de evitar que o cálculo do CV apresente valores demasiadamente elevados para sinais que apresentem médias muito pequenas, como no caso de processos/equipamentos parados com instrumentos medindo valores aleatórios dentro de sua faixa de incerteza, é proposto aqui que o valor mínimo a ser utilizado para a média seja o valor unitário. Caso a média seja superior a 1, deve ser utilizado o seu valor real calculado, senão é usado o valor 1.

### 3.2 Estudo de Caso

Os quatro métodos de detecção de oscilações foram aplicados sobre os 8 sinais mostrados na Figura 3.4-I, que são provenientes de uma plataforma *offshore*. Os dados são fornecidos



por um Sistema de Gestão de Informação de Processo (*Process Information Management System* – PIMS), com tempo de amostragem de 5s e interpolação linear entre as amostras. Foram utilizadas 5000 amostras de cada sinal. O tamanho de 25000 segundos para o intervalo de dados foi selecionado conforme recomendação de THORNHILL e HÄGGLUND (1997), que prevê um tamanho de 50 vezes o período da oscilação presumido (análises preliminares das PSDs dos sinais indicaram a existência de oscilações de períodos de até 500 segundos na maioria dos sinais analisados). Foram selecionados sinais com características oscilatórias, incluindo frequências distintas sobrepostas (sinais 1 a 4), sinais corrompidos por distúrbios (sinais 5 e 6) e sinais com presença de oscilações de pequena amplitude (sinais 7 e 8), visando avaliar o comportamento dos métodos nessas condições.

A Figura 3.4-II apresenta as PSDs desses 8 sinais após a remoção de suas médias, sem a aplicação de pré-tratamento sobre os dados (filtro passa-faixa e tratamento de vazamento espectral), enquanto que a Figura 3.4-III apresenta as PSDs dos 8 sinais após a aplicação de um pré-tratamento adequado.

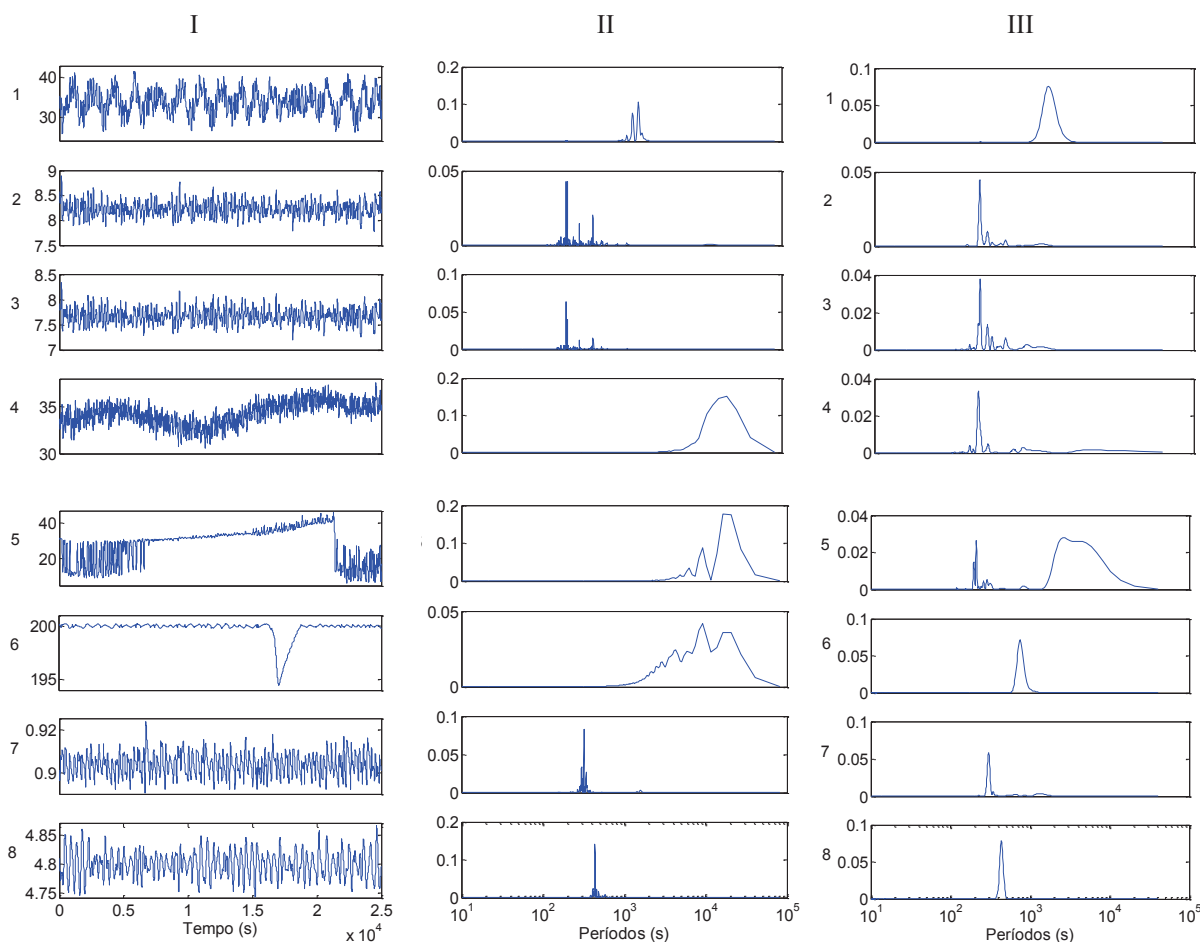


Figura 3.4. Sinais industriais e suas densidades espectrais de potência. I-Sinais no tempo; II-PSD dos sinais sem pré-tratamento; III-PSDs dos sinais após a utilização de pré-tratamento.

A frequência de corte inferior do filtro foi configurada para filtrar oscilações de períodos superiores a  $1/4$  do tamanho do intervalo de dados, que é a máxima oscilação detectável pelos algoritmos, conforme já citado anteriormente. Já a frequência de corte superior foi selecionada para eliminar valores maiores que 99% da frequência de Nyquist do sinal. Para a suavização das PSDs utilizadas nos métodos ACF, ICA e SE foi empregada uma janela gaussiana com  $\alpha_G = 7$ , que eliminou o vazamento espectral sem atenuar de forma acentuada a energia do sinal oscilatório.

A partir da comparação entre as PSDs apresentadas na Figura 3.4, é possível verificar os efeitos da aplicação do pré-tratamento. O efeito do tratamento do vazamento espectral fica nítido nos sinais 1, 2, 3, 7 e 8, onde é possível perceber que múltiplos picos próximos para uma única frequência original do sinal foram eliminados, facilitando a caracterização de oscilações que possuam pouca energia. O efeito da filtragem pode ser visualizado claramente

nas PSDs dos sinais 4, 5 e 6: antes do pré-tratamento, as PSDs eram dominadas por componentes relativos a oscilações de frequência muito baixas, que eclipsavam uma componente oscilatória de período aproximado de 200 segundos nos sinais 4 e 5, e uma de período 760 segundos no sinal 6. A oscilação de 200 segundos também foi detectada nos sinais 2 e 3.

A Tabela 3.2 apresenta os parâmetros usados na configuração individual de cada método. Para o agrupamento das oscilações detectadas será utilizado  $K_\sigma = 1$  (um desvio padrão).

Tabela 3.2. Parâmetros utilizados nas configurações dos métodos.

<b>Método</b>	<b>Parâmetros</b>
ACF	$\varepsilon_p = \mu_{PSD} + \sigma_{PSD}$ $\varepsilon_E = 15\%$
DCT	$SL_1 = 10\sigma_{DCT}$ $SL_2 = 8\sigma_{DCT}$
SE	$\varepsilon_{SE} = \mu_{SE} + 2,5\sigma_{SE}$
ICA	$\varepsilon_{ICA} = \mu_{IC} + \sigma_{IC}$ $Energia = 25\%$ $\% da\ variabilidade = 95\%$

### 3.2.1 Aplicação dos Métodos

A partir das PSDs na Figura 3.4-III é possível identificar os períodos aproximados das principais oscilações que deveriam ser identificadas pelos métodos:

- 210 segundos nos sinais 2, 3, 4 e 5;
- 300 segundos no sinal 7;
- 440 segundos no sinal 8;
- 760 segundos no sinal 6;
- 1590 segundos no sinal 1; e
- 2730 segundos no sinal 5.

Os quatro métodos foram aplicados sobre os 8 sinais apresentados na Figura 3.4-I e as oscilações de períodos 210, 300, 440, 760, 1590 e 2730 foram identificadas por todos os métodos nos sinais esperados. A Figura 3.5 apresenta de forma resumida os períodos das oscilações detectadas em cada sinal.




Figura 3.5. Resultados obtidos pelos algoritmos de detecção para os 8 sinais.

Os gráficos ilustrando os resultados individuais obtidos por cada método são mostrados abaixo.

### 3.2.1.1 Método ACF

A Figura 3.6 apresenta as PSDs individuais de cada um dos oito sinais. As áreas sob as curvas em amarelo representam os picos selecionados com energia relevante e os valores numéricos no interior dos gráficos indicam a energia em termos percentuais de cada pico selecionado e o valor do período em segundos após a verificação dos cruzamentos por zero. A partir dos gráficos é possível perceber que os sinais 1, 2, 3, 4, 6, 7 e 8 apresentaram um único pico relevante na PSD. A exceção é o sinal 5, que apresentou dois picos com energia superior ao limiar de energia.

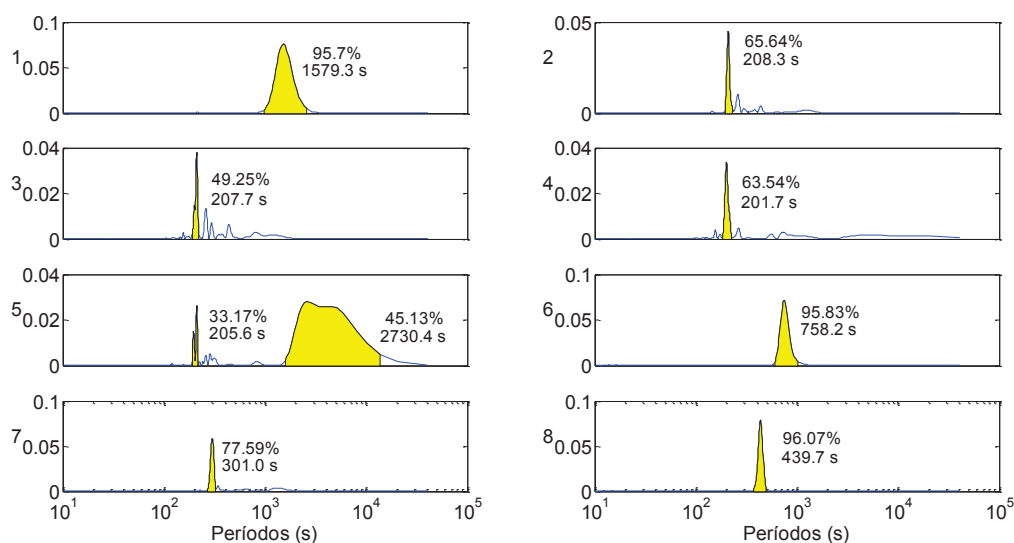


Figura 3.6. Picos com energias relevantes selecionados nas PSDs dos 8 sinais pelo método ACF (áreas em amarelo).

### 3.2.1.2 Método DCT

A Figura 3.7-I apresenta as transformadas DCT dos oito sinais analisados, em que apenas os 500 primeiros pontos foram mostrados nos gráficos com o objetivo de facilitar a visualização dos segmentos selecionados. As duas linhas horizontais representam os limiares utilizados para a seleção dos segmentos que podem estar associados a oscilações, enquanto que os dados em vermelho no gráfico indicam os segmentos selecionados. Já a Figura 3.7-II mostra a transformada DCT inversa dos segmentos selecionados (apenas os 10.000 segundos iniciais de dados foram mostrados nos gráficos para uma melhor visualização). Os valores numéricos no interior dos gráficos indicam o valor do período em segundos após a verificação dos cruzamentos por zero. Assim como no método ACF, apenas o sinal 5 apresentou mais de um segmento selecionado. Nos demais sinais apenas um segmento relevante foi detectado.

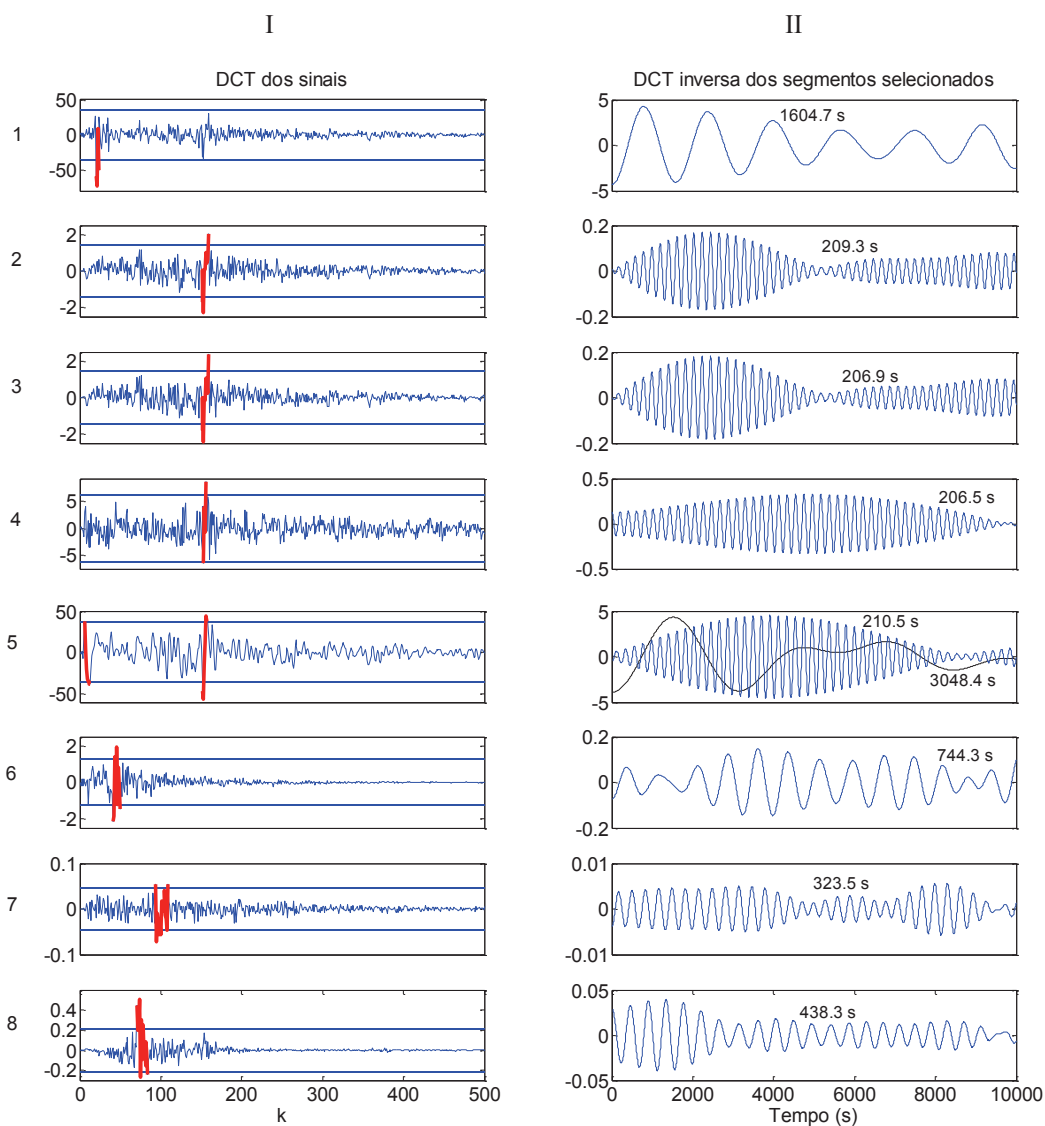


Figura 3.7. DCT e DCT inversa dos 8 sinais industriais. I-DCT dos sinais; II-DCT inversa dos segmentos selecionados (sinais no tempo).

### 3.2.1.3 Método SE

A Figura 3.8 apresenta o envelope espectral obtido para os oito sinais analisados. Os valores numéricos no interior dos gráficos indicam os valores dos picos em segundos selecionados pelo algoritmo.

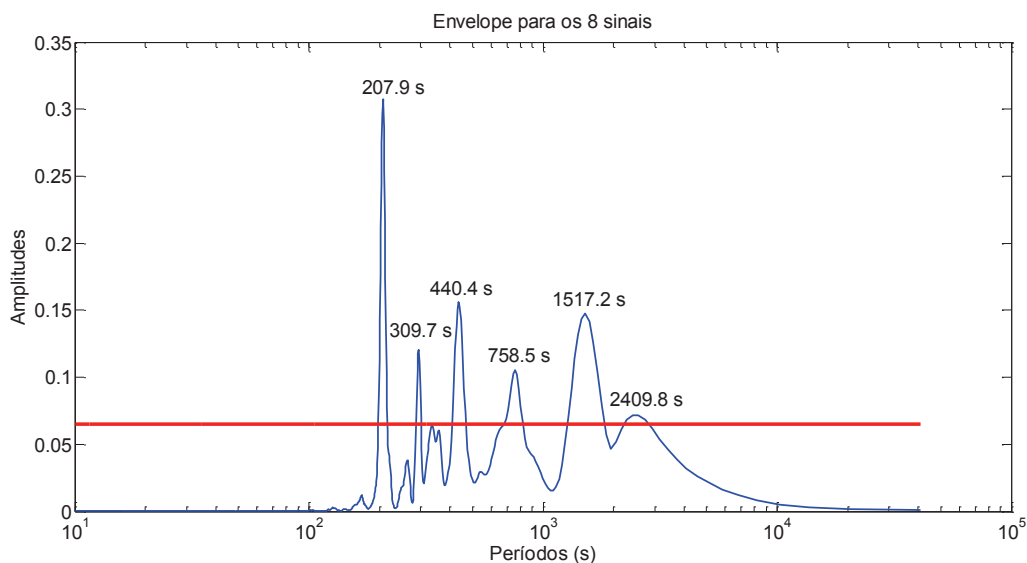


Figura 3.8. Envelope espectral para os 8 sinais.

### 3.2.1.4 Método ICA

A Figura 3.9 apresenta as seis componentes independentes obtidas pelo método ICA. Os valores numéricos no interior dos gráficos indicam a energia em termos percentuais de cada pico selecionado e os respectivos valores de cada pico em segundos.

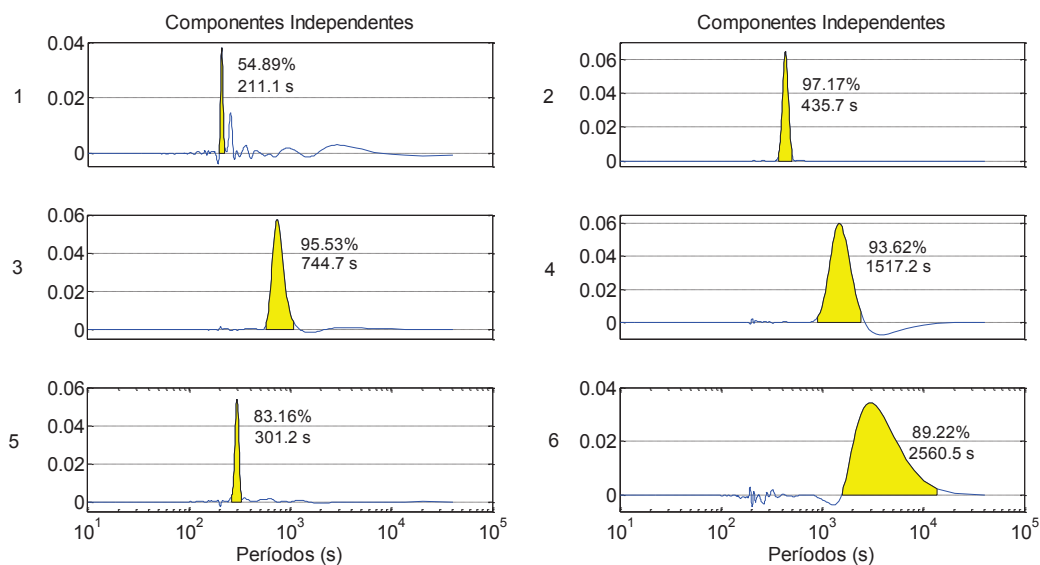


Figura 3.9. Picos com energias relevantes selecionados nas componentes independentes determinadas pelo método ICA (áreas em amarelo).

### 3.2.2 Aplicação do Teste de Regularidade Sobre as Oscilações Detectadas

Os testes de regularidade foram aplicados sobre as oscilações detectadas pelos 4 algoritmos e apenas a oscilação de período 2730 segundos presente no sinal 5 foi descartada em todos os métodos. O gráfico com a PSD desse sinal na Figura 3.4-III apresenta um pico de base irregular para essa oscilação, indicando a possibilidade de não regularidade, que foi confirmada pelos testes de regularidade dos métodos ACF, DCT, SE e ICA.

O resultado da aplicação dos métodos após o descarte dos períodos não regulares é mostrado de forma resumida na Figura 3.10.

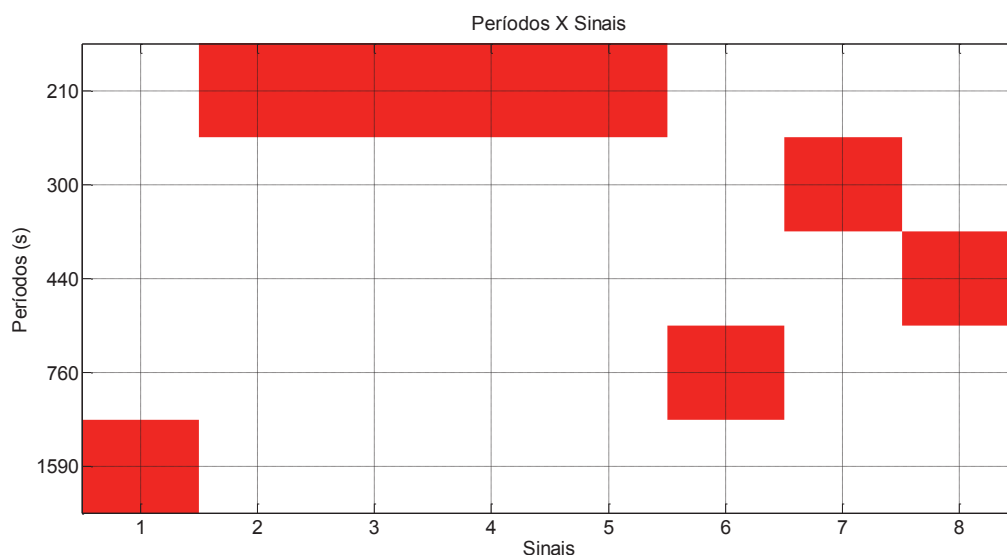


Figura 3.10. Resultados dos algoritmos de detecção para os 8 sinais após a aplicação do teste de regularidade.

### 3.2.3 Avaliação da Variabilidade das Oscilações Detectadas

O Coeficiente de Variação (CV) de cada sinal, que permite expressar a variabilidade dos dados excluindo a influência da ordem de grandeza e da unidade de medida da variável, é mostrado na Figura 3.11-I, onde é possível verificar que os sinais 1 e 5 apresentam o maior CV.



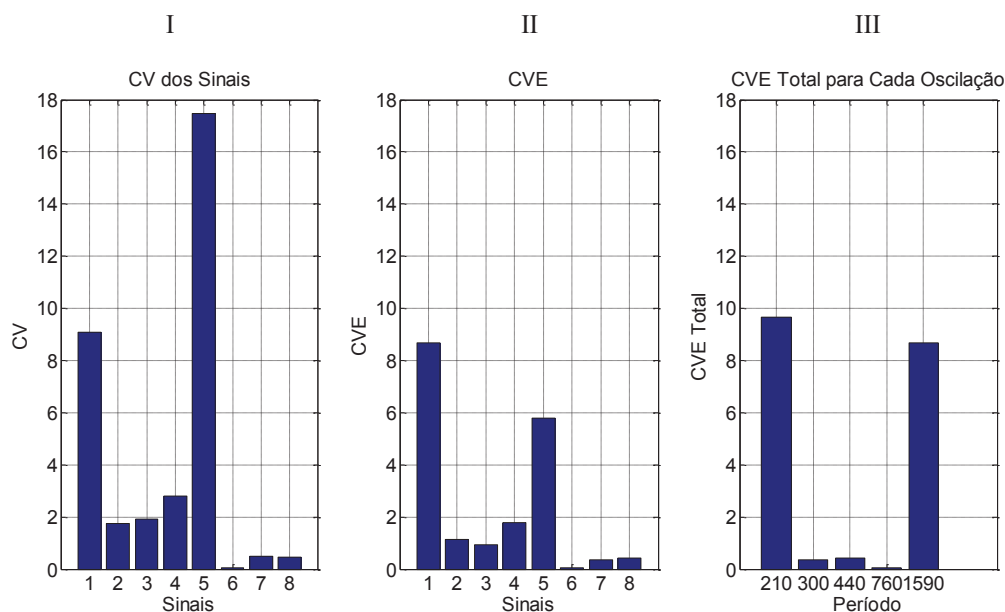


Figura 3.11. Coeficiente de variação. I-CV de cada um dos 8 sinais; II-CVE das oscilações detectadas em cada sinal; III-CVE total para cada período de oscilação regular detectado.

Entretanto, conforme já citado, o CV representa a variabilidade total presente no sinal e não apenas a variabilidade causada pelas oscilações detectadas, e por isso é proposto que seja utilizada a energia relativa às bandas de frequência relacionadas a cada componente oscilatória identificada na PSD como índices de ponderação do CV (CVE). A Figura 3.11-II apresenta o CVE para todas as oscilações detectadas em cada sinal analisado. Após a aplicação do fator de ponderação, verifica-se que a oscilação detectada no sinal 1 passou a apresentar um maior indicativo de variabilidade do que a oscilação presente no sinal 5. Isso acontece porque a oscilação regular detectada no sinal 5 correspondia a apenas 33,17% da energia do espectro da PSD do sinal, enquanto que 45,13% da energia do espectro era relativa a um distúrbio não regular.

Com o objetivo de quantificar a variabilidade total ocasionada por cada um dos cinco períodos de oscilação diferentes detectados pelos algoritmos, somou-se seus CVEs calculados. Esse indicativo é mostrado na Figura 3.11-III e permite verificar que as oscilações de período 210 segundos encontrada nos sinais 2, 3, 4 e 5 e de período 1590 segundos encontrada no sinal 1 são as que mais impactam na variabilidade do conjunto de sinais analisados.

O CVE pode ser usado como um artifício de caráter gerencial para reduzir a quantidade de variáveis de sinais que devem ser verificadas de forma prioritária para a obtenção de ganhos

consideráveis na redução da variabilidade do conjunto de sinais monitorados. Por exemplo, a utilização de um limiar nos algoritmos de detecção que fizessem com que apenas oscilações de CVE superior a 2 fossem selecionadas resultaria na identificação de apenas duas oscilações, uma de período 210 segundos no sinal 5 e outra de período 1590 segundos no sinal 1, cujos CVEs correspondem a 42,6% da soma dos CVs de todos os sinais. Detectadas as oscilações que estejam causando maiores impactos na operação da planta, devem ser utilizados algoritmos que efetuem a busca da causa raiz, com o objetivo de sanar o comportamento oscilatório.

### **3.2.4 Avaliação Geral dos Métodos**

Após a aplicação da estratégia descrita neste artigo, os quatro métodos detectaram as oscilações que contribuíram de forma mais significativa para o aumento da variabilidade nos sinais analisados. Entretanto, a configuração dos parâmetros individuais do método ACF se mostrou mais simples, já que os efeitos de seus ajustes resultam na seleção ou não de picos nas PSDs dos sinais, que podem ser facilmente visualizados em gráficos auxiliares.

Os ajustes dos parâmetros relacionados ao pré-tratamento (pré-filtragem e tratamento de vazamento espectral), comuns a todos os métodos, se mostraram muito importantes e são feitos facilmente observando as PSDs e os sinais no tempo.

Baseado na experiência do autor, é proposto que os métodos sejam configurados de acordo com as características dos sinais a serem analisados. As análises periódicas subsequentes não requerem novos ajustes, pois a dinâmica do processo muda muito pouco. Além disso, a utilização de técnicas para descartar da análise oscilações com pequena variabilidade permite direcionar a busca da causa da oscilação naqueles sinais que causam grandes impactos na variabilidade dos sinais da planta, reduzindo a quantidade de sinais a serem investigados pela equipe de operação.

## 4 DETECÇÃO DE OSCILAÇÕES EM SINAIS AFETADOS POR DISTÚRBIOS NÃO OSCILATÓRIOS

Após a comparação dos quatro métodos de detecção de oscilações, serão realizadas análises sobre um conjunto maior de 32 sinais, que fazem parte de um mesmo subsistema em uma Plataforma *Offshore* de Produção de Óleo e Gás. Esses sinais são corrompidos por distúrbios não oscilatórios consideráveis. Inicialmente será efetuada uma análise sobre uma janela de 24 horas de dados com o objetivo de avaliar a aplicação da metodologia aqui proposta. Feita essa primeira análise, o algoritmo será aplicado em outras três janelas de dados sequenciais de mesmo tamanho com o objetivo de avaliar a repetibilidade dos resultados obtidos. Para essas análises, optou-se pela utilização do método ACF apenas, já que a configuração de seus parâmetros individuais se mostrou mais simples e os quatro métodos apresentaram resultados similares para os sinais industriais de características distintas analisados na seção anterior.

Esse capítulo abordará também considerações a respeito do descarte de dados corrompidos por distúrbios não oscilatórios e *outliers*, que interferem na aplicação dos algoritmos de detecção de oscilações. A metodologia proposta para o descarte de dados não regulares é apresentada na próxima seção.

### 4.1 Problemas com outliers e distúrbios acentuados presentes nos sinais

Os dados industriais podem apresentar uma série de *outliers* e de distúrbios não oscilatórios acentuados. A aplicação dos filtros de pré-tratamento, necessários para o bom funcionamento dos algoritmos de detecção de oscilações, sobre sinais com essas características pode resultar na inclusão de uma dinâmica oscilatória de baixa frequência que pode levar a falsas detecções, conforme pode ser observado na Figura 4.1, que apresenta um sinal corrompido por distúrbio antes e após a aplicação de um pré-filtro com frequência de corte superior igual a 99% da frequência de Nyquist do sinal e com frequência de corte inferior configurada para filtrar oscilações de períodos superiores a 1/4 do tamanho do intervalo de dados.




Figura 4.1. Sinais industriais com presença de distúrbios antes e depois da utilização de filtro de pré-tratamento.

Por outro lado, a não aplicação do filtro de pré-tratamento faz com que a PSD apresente amplitudes relevantes basicamente apenas nas frequências associadas aos distúrbios (períodos altos), fazendo com que praticamente nenhuma oscilação seja detectada no conjunto de sinais. A Figura 4.2 ilustra essa situação para o mesmo intervalo de tempo apresentado na Figura 4.1.




Figura 4.2. PSDs dos sinais sem a utilização de filtro de pré-processamento.

Com o objetivo de evitar esses problemas ocasionados por filtros aplicados sobre dados com forte presença de *outliers* e distúrbios, foi proposta uma metodologia com a finalidade de selecionar apenas segmentos de dados livres de distúrbios não oscilatórios (MUNARO, VIEIRA JUNIOR, *et al.*, 2017). O algoritmo empregado para a seleção dos dados (algoritmo SED) pode ser visualizado no fluxograma apresentado na Figura 4.3.

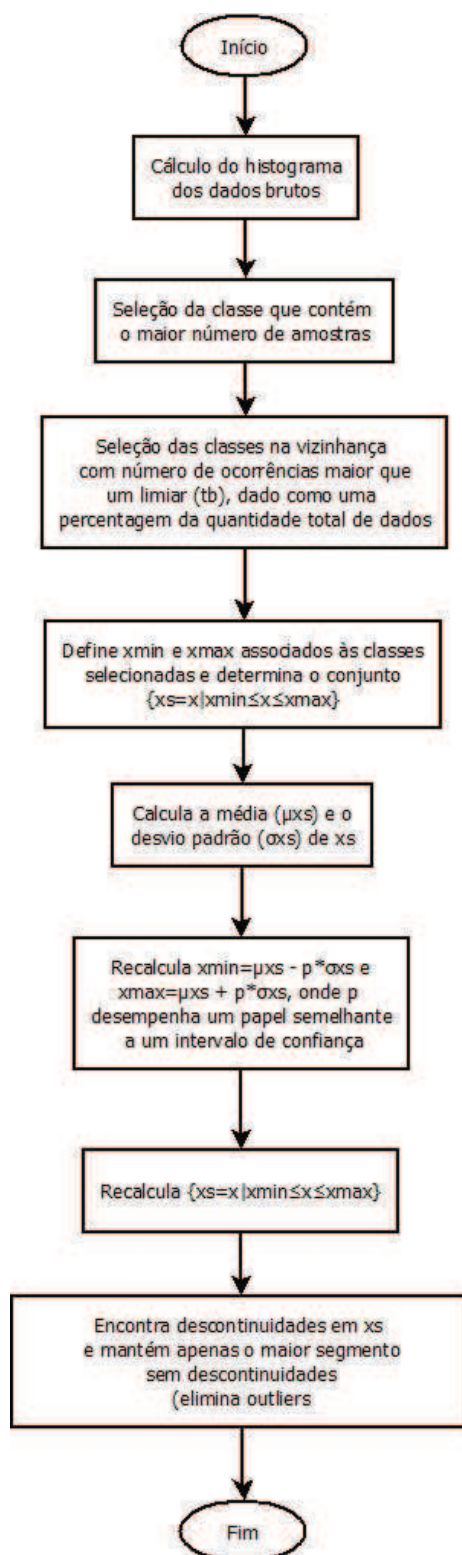


Figura 4.3. Metodologia para descarte de distúrbios e *outliers*.

Com o objetivo de tornar a explicação sobre o funcionamento do algoritmo SED mais didática, serão usados os dois sinais de processo apresentados na Figura 4.4 como exemplo.

Inicialmente, os sinais analisados têm seus dados classificados de acordo com o seu valor, sendo divididos em classes uniformes. No exemplo em questão, foram utilizadas 20 classes e as linhas horizontais na Figura 4.4 representam essas divisões.




Figura 4.4. Sinais de processo avaliados pelo algoritmo de descarte de distúrbios e *outliers* e classes utilizadas na seleção dos dados.

Feita a divisão dos dados em classes, seleciona-se aquela com o maior número de dados, conforme Figura 4.5-I (dados em vermelho), já que ela é a mais representativa para o sinal em questão. Depois é verificado se a classe imediatamente superior possui uma quantidade mínima de dados, que seja superior a um determinado limiar  $t_b$  (no exemplo em questão foi utilizado um limiar de 2,5% da quantidade de dados). Caso a classe possua uma quantidade de dados superior a  $t_b$ , seus dados também são selecionados e faz-se a busca na próxima classe, e assim sucessivamente. Caso a classe possua elementos em quantidade inferior à  $t_b$ , o algoritmo SED interrompe a seleção e é iniciada a busca nas classes inferiores, de modo que o processo é repetido até que  $t_b$  não seja atendido. A Figura 4.5-II apresenta os dados selecionados após a busca nas classes superiores, enquanto que Figura 4.5-III apresenta os dados após o término da busca pelas classes inferiores.

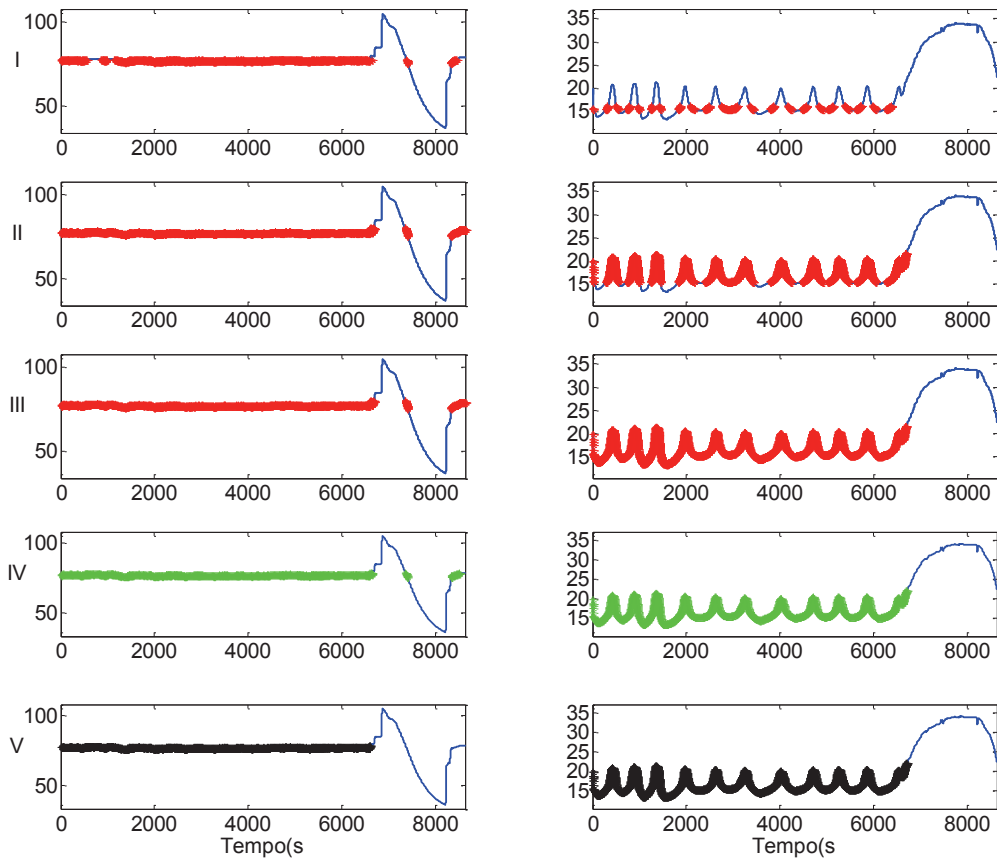


Figura 4.5. Metodologia para descarte de distúrbios e outliers.

Após a seleção inicial dos dados, devem ser definidos os valores mínimo ( $x_{min}$ ) e máximo ( $x_{max}$ ) associados às classes selecionadas, resultando no conjunto  $\{x_s=x|x_{min}\leq x\leq x_{max}\}$ . Feito isso, são calculadas a média ( $\mu_{x_s}$ ) e o desvio padrão ( $\sigma_{x_s}$ ) desse conjunto. A partir de  $\mu_{x_s}$  e  $\sigma_{x_s}$ ,  $x_{min}$  e  $x_{max}$  devem ser recalculados como:

$$\begin{aligned} x_{min} &= \mu_{x_s} - p\sigma_{x_s} \\ x_{max} &= \mu_{x_s} + p\sigma_{x_s} \end{aligned} \quad (4.1)$$

onde  $p$  desempenha um papel semelhante a um intervalo de confiança.

Para os dois sinais em questão, foi utilizado  $p=3$ . A nova seleção de dados  $x_s$  é recalculada de acordo com  $\{x_s=x|x_{min}\leq x\leq x_{max}\}$  e é mostrada na Figura 4.5-IV (dados selecionados em verde). Em seguida, o algoritmo SED elimina eventuais *outliers* presentes nos dados através da verificação das discontinuidades dos dados selecionados. Caso o número de pontos entre dois segmentos sucessivos seja inferior a um determinado limiar (no exemplo em questão foi utilizado o máximo de três pontos) o algoritmo descarta esses pontos e faz a junção entre os segmentos sucessivos.

Após todas essas etapas, o algoritmo SED finalmente seleciona o maior segmento contínuo de dados regulares, resultando no descarte de distúrbios e de *outliers*. A seleção final de dados para os dois sinais é mostrada na Figura 4.5-V (dados selecionados em preto).

## 4.2 Estudo de Caso

O método de detecção ACF foi aplicado sobre os 32 sinais de processo mostrados na Figura 4.6. Os sinais são provenientes de uma plataforma *offshore* de produção de óleo e gás e seus dados são fornecidos por um PIMS, com tempo de amostragem de 10s e interpolação linear entre as amostras, tendo sido utilizadas 8.640 amostras de cada sinal, totalizando 24 horas de dados. A metodologia de seleção de segmentos de dados regulares foi aplicada sobre esses sinais. A cor vermelha na Figura 4.6 representa os segmentos selecionados, enquanto que a cor azul representa os dados descartados.



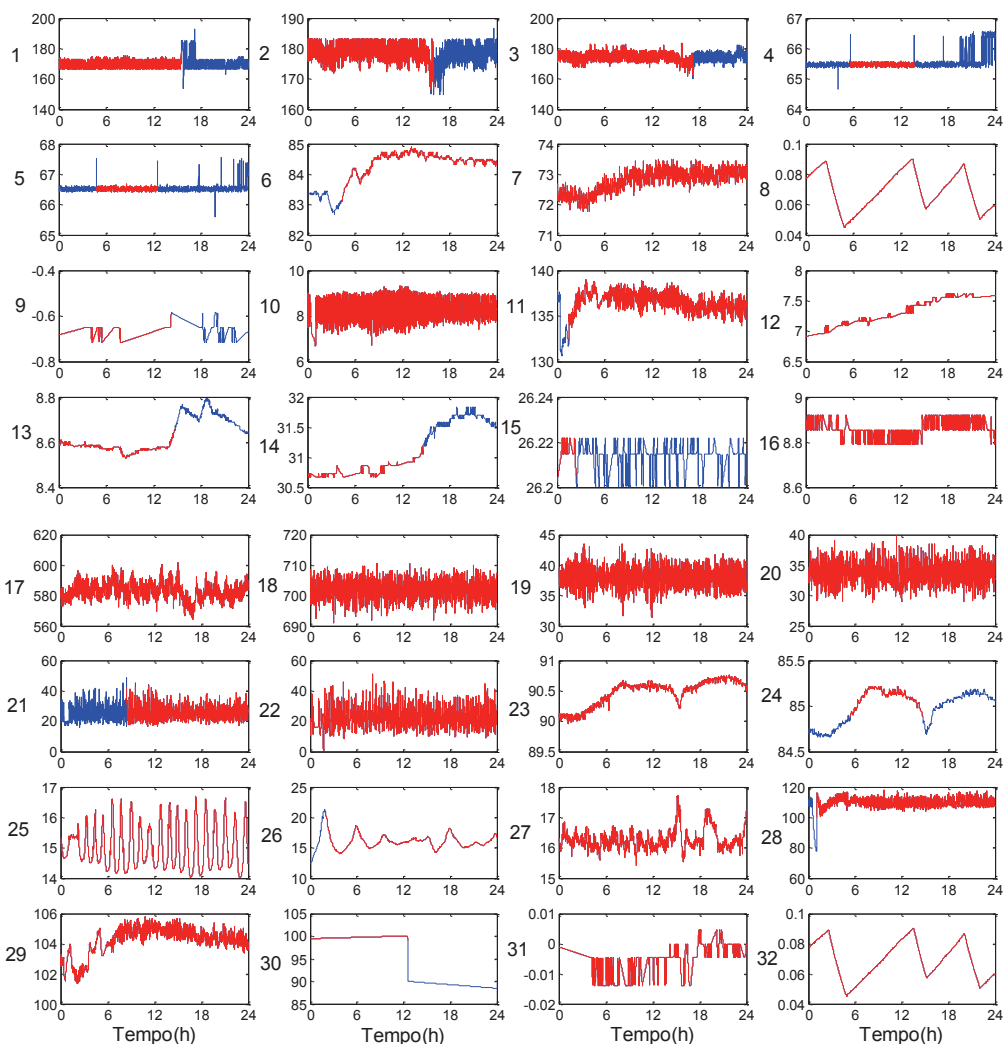


Figura 4.6. Sinais 1 a 32 no tempo: dados selecionados em vermelho e dados descartados em azul.

O tamanho do intervalo de dados utilizado na análise foi escolhido de acordo com o histórico de testes e simulações já efetuados sobre os dados de processo utilizados, em que foi verificado que a maioria das oscilações detectadas possuíam períodos de até 20.000 segundos. Como o maior período de oscilação detectável pelos métodos de detecção de oscilações é igual a 1/4 do tamanho do intervalo de dados, tem-se que o tamanho mínimo do intervalo necessário para garantir que um período de 20000 segundos seja selecionado é igual a:

$$20000 \times 4 = 80000 \text{ segundos} = 22,22 \text{ horas} \quad (4.2)$$

Optou-se por utilizar um intervalo de tamanho igual a 24 horas para a realização da análise. A utilização desse tamanho de intervalo permite que sejam realizadas análises diárias

no processo em questão, facilitando o acompanhamento da evolução dos resultados e a elaboração de relatórios de caráter gerencial.

A frequência de corte inferior do filtro foi configurada para filtrar oscilações de períodos superiores a 1/4 do tamanho do intervalo de dados, que é a máxima oscilação detectável pelo algoritmo, enquanto que a frequência de corte superior foi selecionada para eliminar valores maiores que 99% da frequência de Nyquist do sinal. Para a suavização das PSDs foi empregada uma janela gaussiana com  $\alpha_G=3$ , que eliminou o vazamento espectral sem atenuar de forma acentuada a energia do sinal oscilatório. Com relação às configurações individuais do método ACF, foi utilizado o limiar de potência igual a  $\varepsilon_p = \mu_{PSD} + 1\sigma_{PSD}$  e o limiar de energia igual a 10%.

A Figura 4.7 apresenta as PSDs dos sinais sem pré-tratamento (filtro passa-faixa e tratamento do vazamento espectral) e sem a aplicação da metodologia de seleção de dados regulares, enquanto que na Figura 4.8 são exibidas as PSDs após a aplicação de um tratamento adequado sobre os sinais.

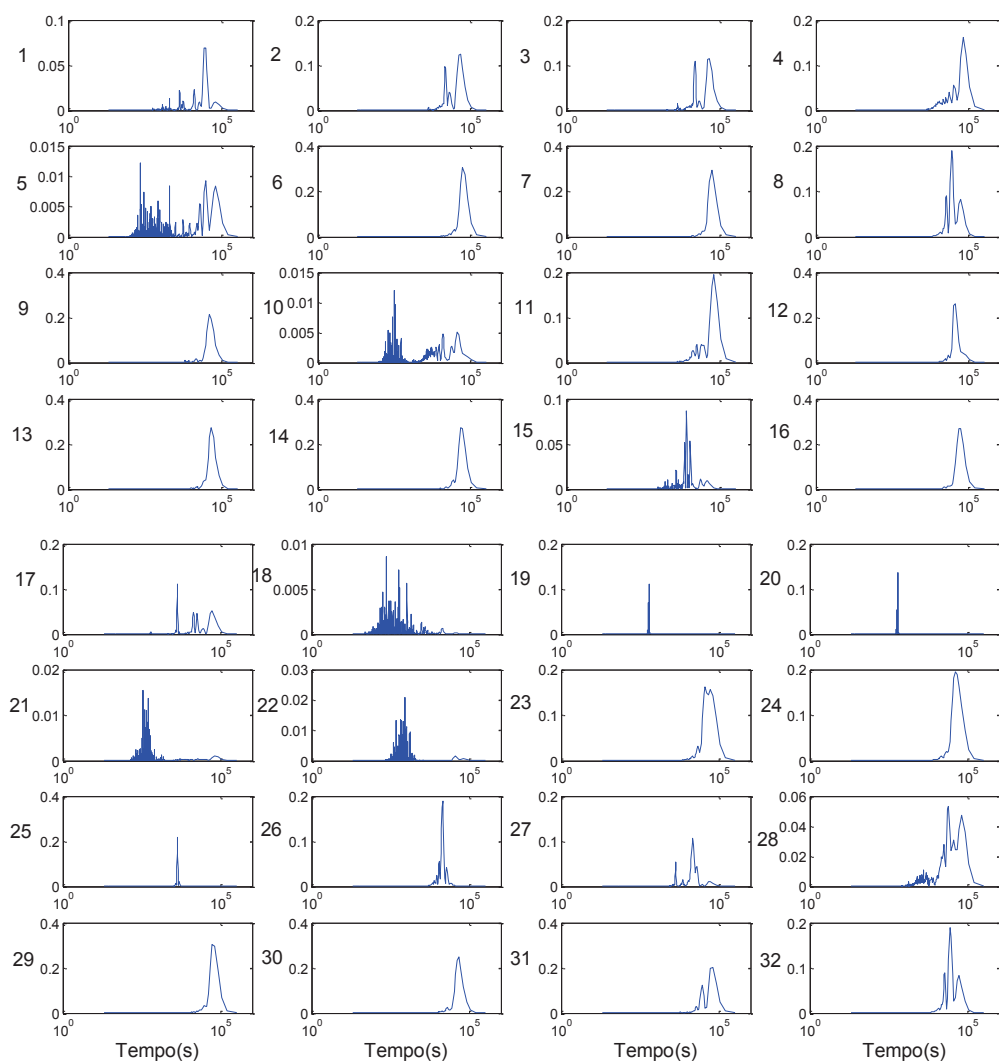


Figura 4.7. PSDs dos 32 sinais sem a aplicação de pré-tratamento e sem a aplicação da metodologia de seleção de dados regulares.

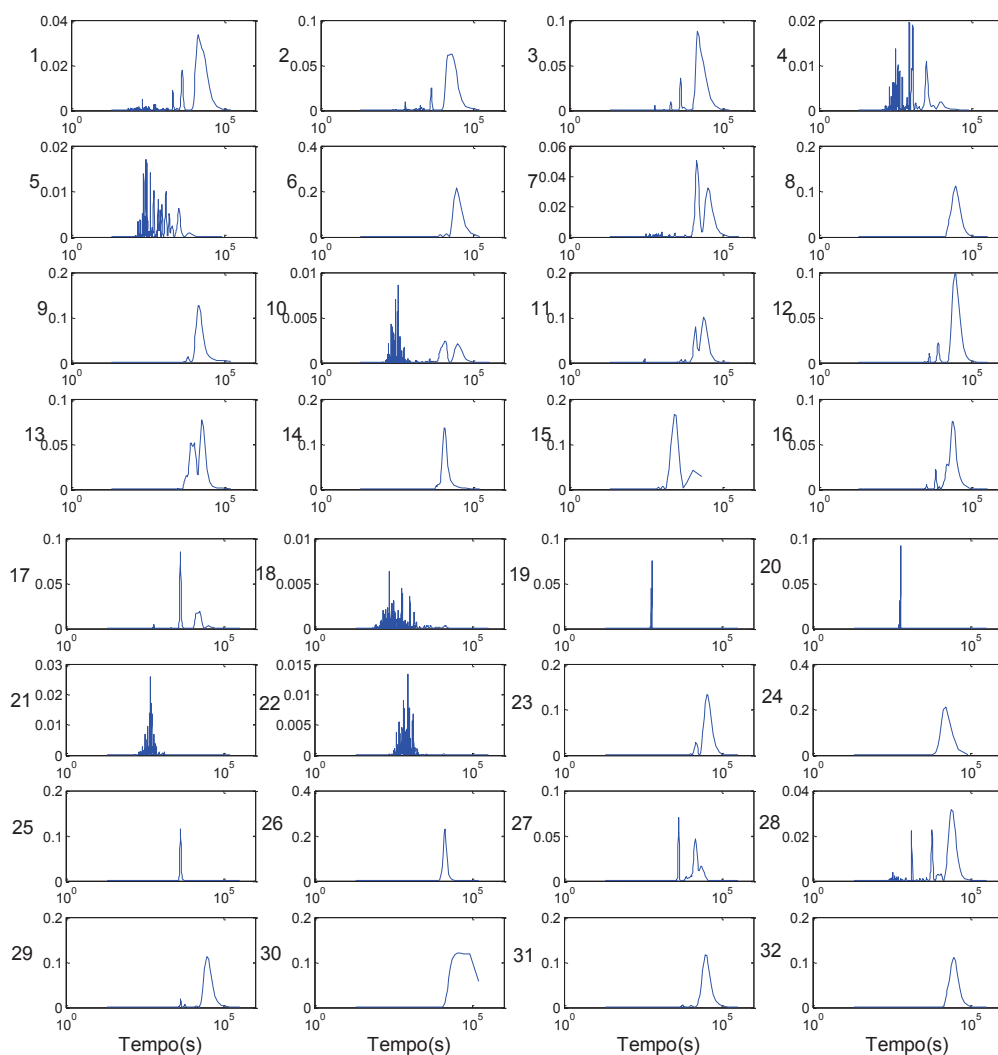


Figura 4.8. PSDs dos 32 sinais após a aplicação de um tratamento adequado sobre os sinais.

A partir da comparação entre essas duas figuras verifica-se os efeitos da ausência do filtro de pré-processamento e da metodologia de seleção de segmentos não regulares. Como exemplo, pode-se verificar as diferenças entre as PSDs dos sinais 4 e 28, em que as PSDs sem tratamento apresentam picos em baixas frequências (períodos altos) que impossibilitam a detecção de oscilações de períodos mais baixos.

Os períodos detectados em cada sinal individualmente nas análises serão agrupados através de seus desvios padrões (THORNHILL, HUANG e ZHANG, 2003), conforme apresentado na seção 3.1.5. Para isso, foi utilizado um desvio padrão durante o agrupamento dessas oscilações ( $K_{\sigma} = 1$ ).

Entretanto, a utilização dos desvios padrões para agrupar as detecções efetuadas em um conjunto com muitos sinais poderia resultar na obtenção de uma grande quantidade de períodos de oscilações distintos, dificultando a aplicação de uma metodologia gerencial mais simples para a identificação e correção dos principais problemas que afetam a planta por parte da equipe de operação. Desse modo, os períodos resultantes dos agrupamentos individuais detectados em cada um dos 32 sinais serão classificados em dez grandes grupos, cujos centros são linearmente espaçados entre o menor e o maior valor do período detectado na análise. Ou seja, é proposto aqui que todas as oscilações detectadas sejam reunidas em uma quantidade limitada de grupos de períodos similares, facilitando a identificação e o trabalho de correção dos problemas por parte da equipe de operação da planta.

Considerando esse agrupamento, a Figura 4.9 apresenta as detecções efetuadas nos 32 sinais (círculos em azul) e as divisões efetuadas para agrupamento dos períodos detectados (linhas horizontais em verde).

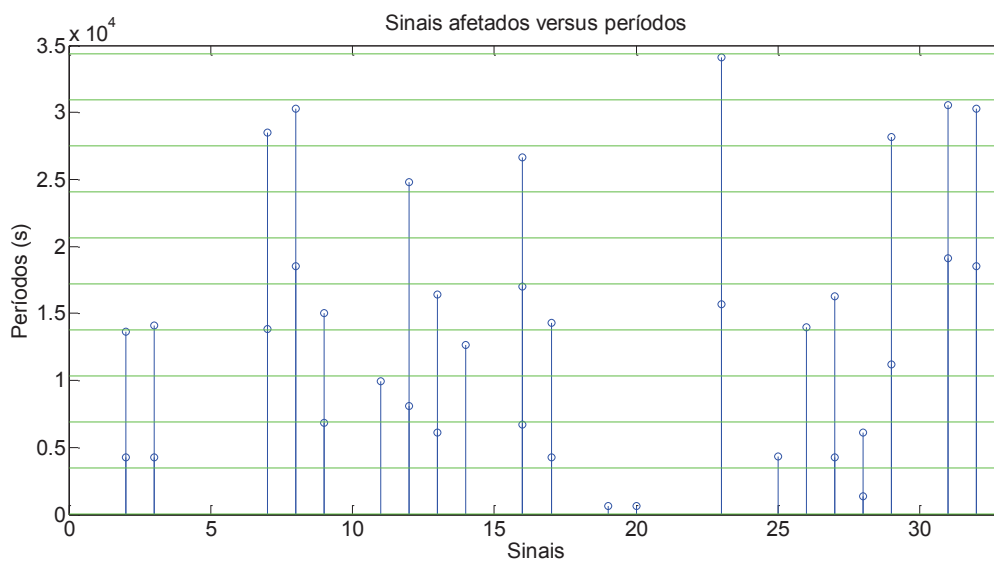


Figura 4.9. Períodos detectados em cada um dos 32 sinais.

A Figura 4.10 traz o CVE acumulado para cada grupo de oscilações, enquanto que a Figura 4.11 indica o número de variáveis afetadas por cada grupo de períodos. O CVE acumulado de cada análise é dado pela soma dos CVEs relativos a cada detecção de um determinado grupo de períodos.

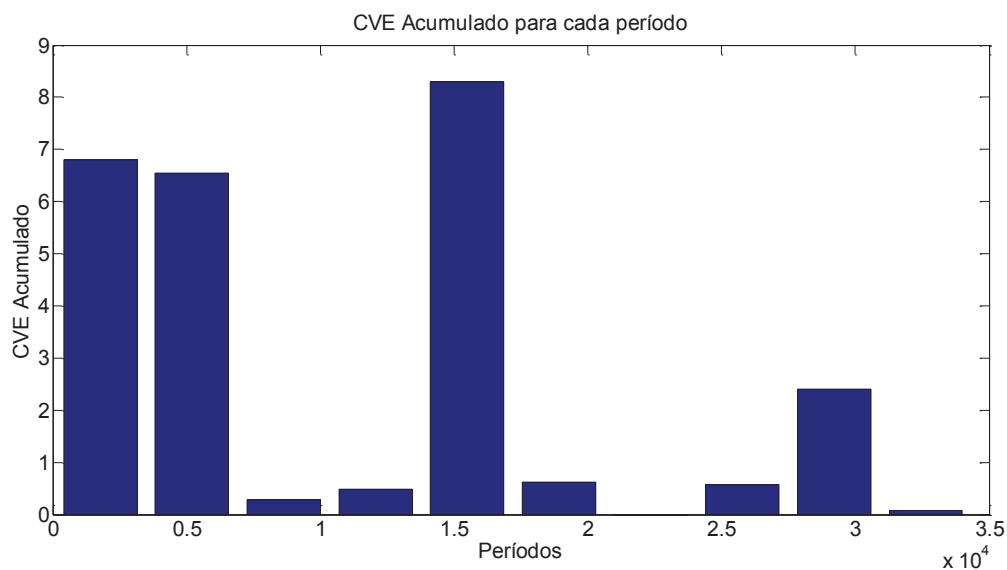


Figura 4.10. CVE acumulado de cada grupo de oscilações detectado.

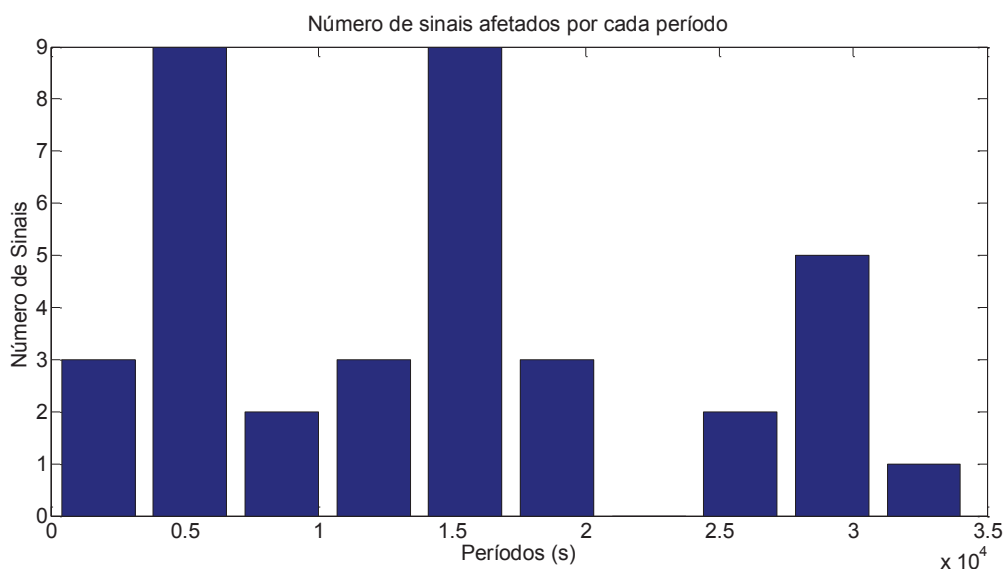


Figura 4.11. Número de sinais afetados por cada grupo de oscilações detectado.

A partir da Figura 4.10 verifica-se que três oscilações se destacam como causadoras do maior impacto na variabilidade do processo, sendo, respectivamente, as oscilações representadas pelos períodos aproximados de 15.492, 1.778 e 5.207 segundos. Essas três oscilações respondem por 82,90% de todo o CVE calculado para todas as detecções. Os períodos de 15.492 e 5.207 foram detectados em um maior número de sinais (9 sinais cada), enquanto que o período de 1.778 segundos foi detectado apenas em três sinais. Sendo assim, verifica-se que a utilização de forma isolada do indicador número de variáveis afetadas pode levar a conclusões precipitadas, uma vez que um período de oscilação que afeta poucos sinais

(período de 1.778 segundos, por exemplo) pode apresentar CVE acumulado e impactar mais na variabilidade do processo do que um outro período que afeta um maior número de sinais. A Figura 4.12 apresenta o CVE calculado em cada sinal para as três oscilações principais.

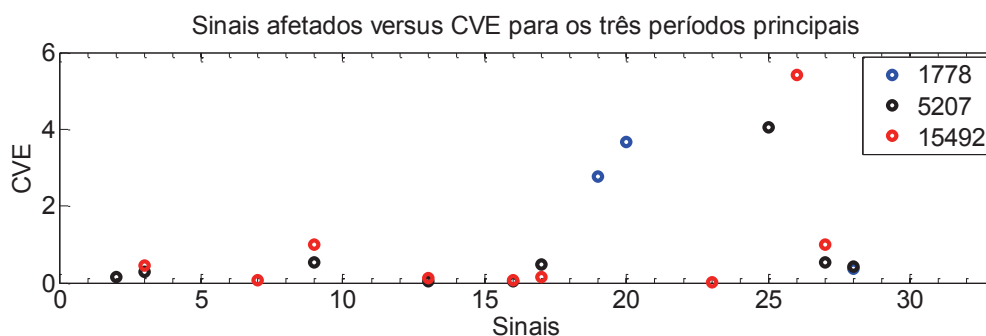


Figura 4.12. CVE para as três oscilações principais.

A partir da Figura 4.12 é possível perceber que as oscilações detectadas nos sinais 19, 20, 25 e 26 apresentaram CVEs mais elevadas que as outras oscilações e por isso deveriam ser avaliados de forma prioritária, já que provavelmente as possíveis causas dessas três oscilações se encontram nesses sinais.

De forma geral, é pouco comum a existência simultânea de uma quantidade elevada de distúrbios oscilatórios de naturezas distintas que impactem consideravelmente a variabilidade do conjunto de sinais de um processo industrial. Por exemplo, os estudos de caso abordados por THORNHILL, SHAH, *et al.* (2002) indicaram a necessidade de no máximo três componentes principais para representar de forma satisfatória o espectro dos sinais analisados. Foi calculado o modelo PCA (*Principal Component Analysis*) para as PSDs dos sinais analisados, de onde verificou-se que as três primeiras componentes eram capazes de explicar 90,14% da variância do conjunto de sinais, conforme mostrado na Figura 4.13. Sendo assim, este trabalho propõe que os três grupos de oscilações que apresentarem o maior CV acumulado sejam tratadas de forma prioritária pela equipe de operação da planta, já que a resolução desses problemas resultará em ganhos consideráveis na redução da variabilidade da planta.

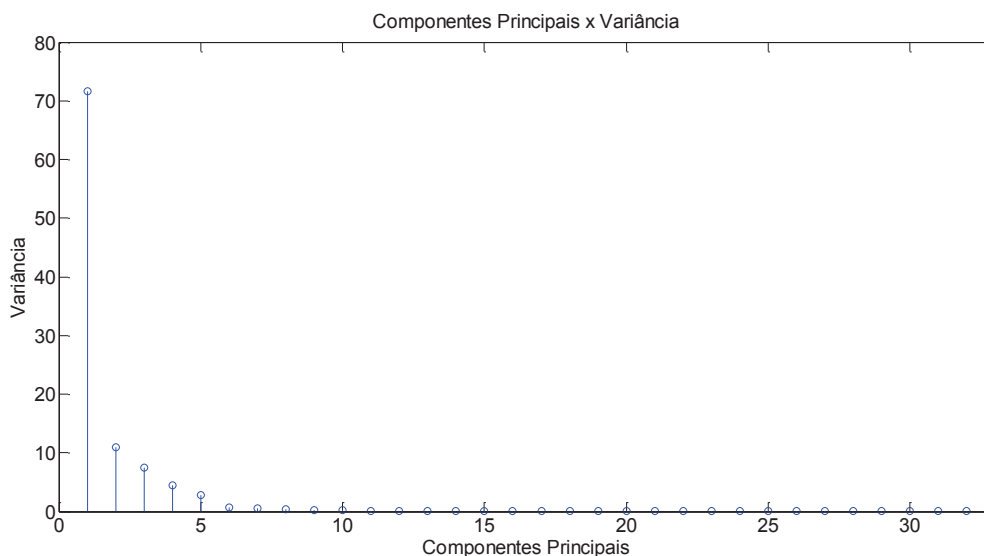


Figura 4.13. Componentes principais versus variância para o conjunto de PSDs dos sinais analisados.

### 4.3 Estudo de Caso – Repetibilidade das Análises

Com o objetivo de avaliar a repetibilidade dos resultados obtidos pelo algoritmo de detecção sobre os 32 sinais avaliados na seção anterior, o método ACF foi aplicado em três novas janelas de dados de 24 horas, subsequentes ao intervalo de dados avaliado anteriormente (dia 1). A Figura 4.14, a Figura 4.15 e a Figura 4.16 apresentam os 32 sinais no tempo para os dias 2, 3 e 4, respectivamente, bem como os dados selecionados pela metodologia de seleção (dados em vermelho). A Figura 4.17 apresenta o percentual médio de retenção de dados dos 32 sinais para as quatro análises efetuadas. Esse indicador está diretamente ligado à presença de distúrbios e *outliers* na janela de dados avaliada. Quanto menor for esse percentual, maior será a presença de distúrbios e menor será a confiabilidade dos resultados obtidos. Para os quatro dias analisados, esse percentual se manteve em torno de 80%.



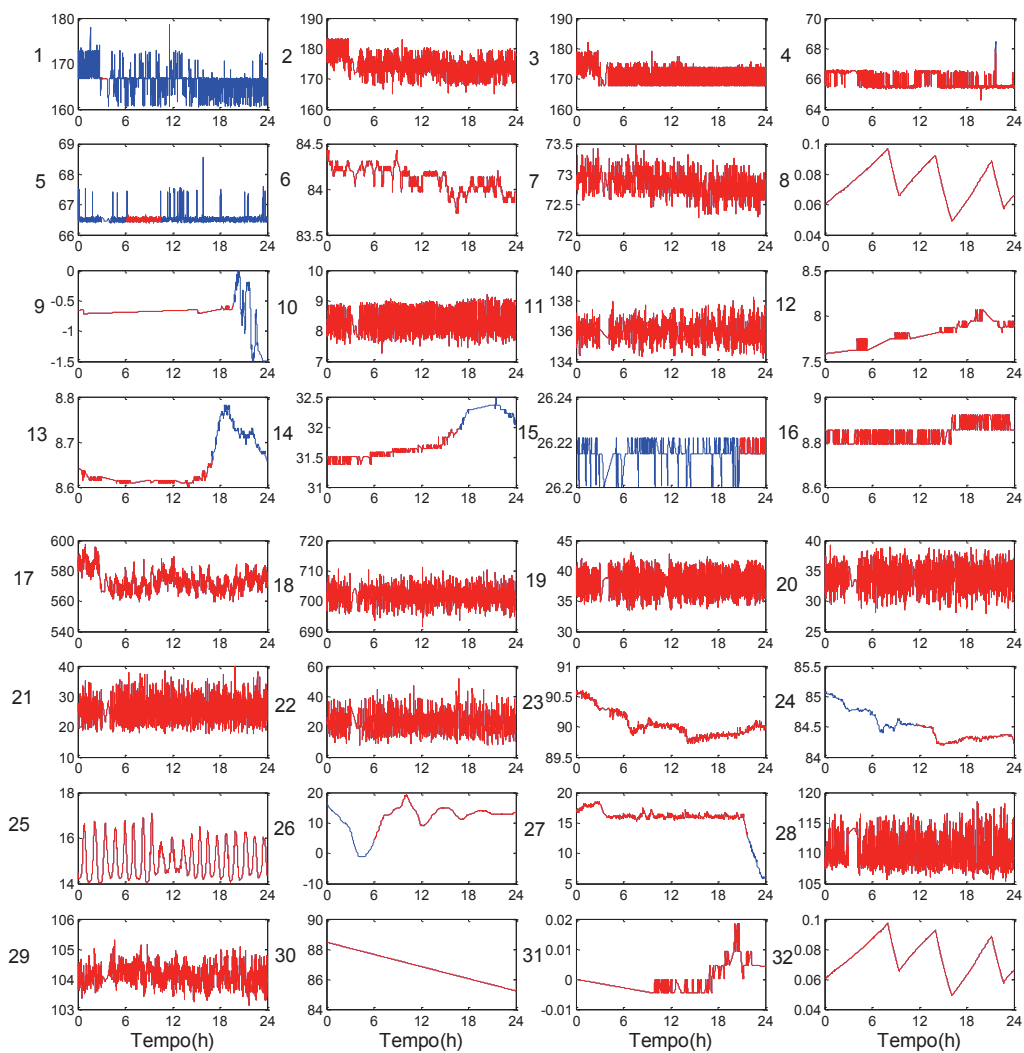


Figura 4.14. Sinais 1 a 32 no tempo para o dia 2: dados seleccionados em vermelho e dados descartados em azul.

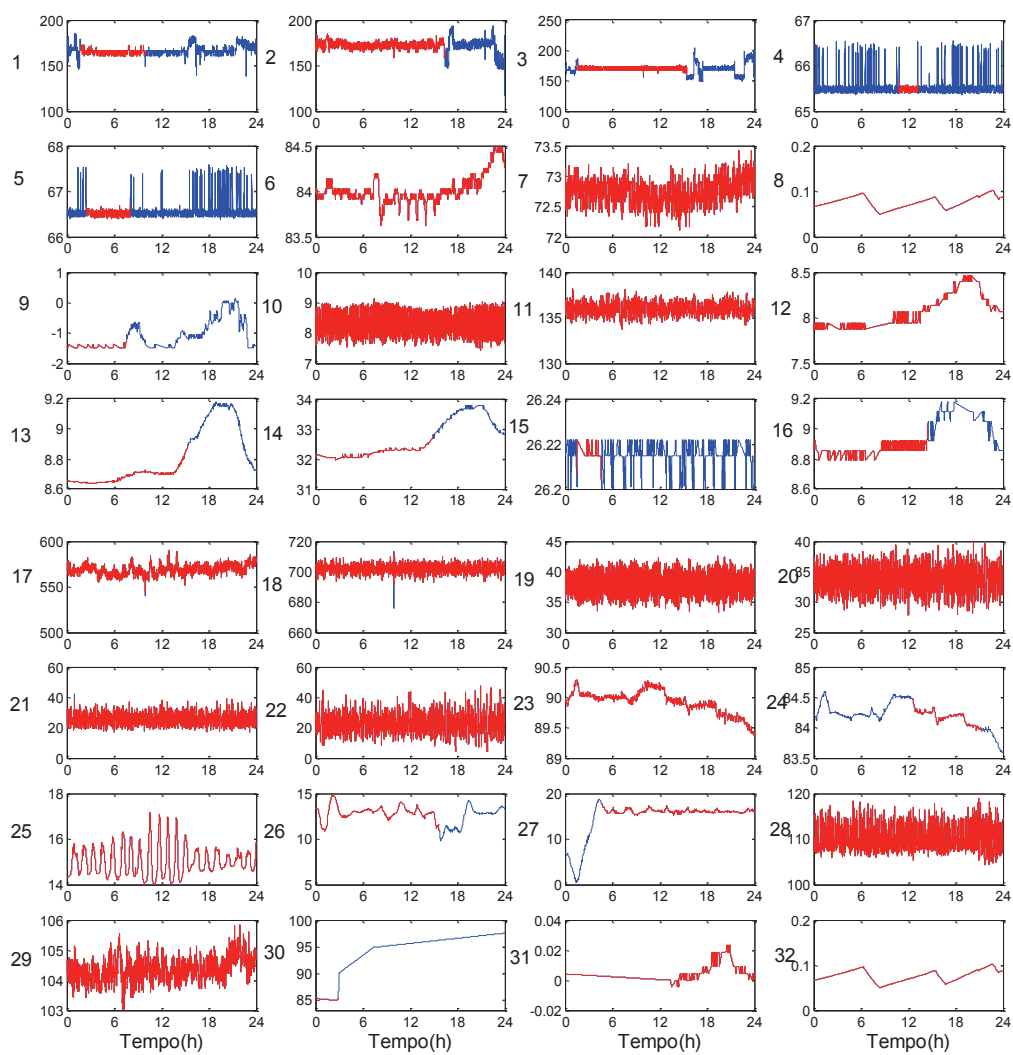


Figura 4.15. Sinais 1 a 32 no tempo para o dia 3: dados seleccionados em vermelho e dados descartados em azul.

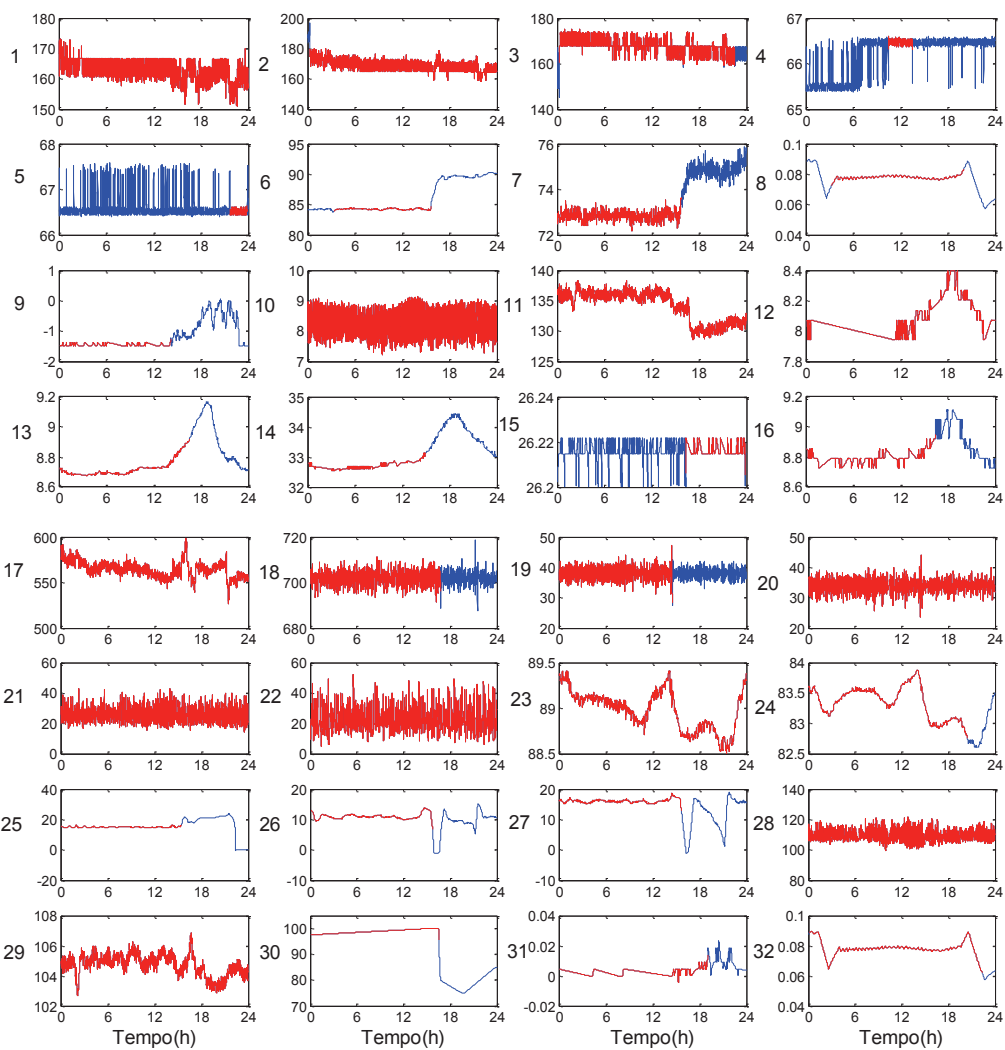


Figura 4.16. Sinais 1 a 32 no tempo para o dia 4: dados seleccionados em vermelho e dados descartados em azul.




Figura 4.17. Percentual médio de retenção de dados para as quatro análises sequenciais efetuadas sobre os 32 sinais.

O objetivo da avaliação da repetibilidade das análises é criar um indicador de caráter gerencial para a equipe de operação da planta. Os períodos das oscilações retornadas que se repetirem ao longo do tempo em um ou mais sinais devem chamar mais a atenção da equipe de operação, já que em tese seriam relativas a um distúrbio que se mantém ao longo do tempo. Por outro lado, as frequências que aparecerem em um único intervalo de dados, por exemplo, não mereceriam tanto a atenção do operador, já que poderiam estar ligadas a algum distúrbio temporário, não tão relevante e talvez até mesmo sem possibilidade de correção. Sendo assim, é proposta a utilização de um gráfico gerencial que mostre de forma simplificada os três principais períodos de oscilação detectados em cada análise bem como os CVEs associados a eles.

Para isso, o algoritmo de detecção de oscilações foi configurado com os mesmos parâmetros empregados na análise efetuada para o dia 1. Os períodos detectados nos 32 sinais em cada análise foram novamente classificados em dez grandes grupos, com centros linearmente espaçados entre o menor e o maior valor do período detectado nas quatro análises. A Figura 4.18 apresenta os gráficos gerenciais propostos.




Figura 4.18. Gráficos gerenciais para os 4 dias analisados: três principais oscilações detectadas (superior) e CVEs associados a essas oscilações (inferior).

A partir da Figura 4.18 verifica-se que as oscilações de períodos 1.778 e 5.207 segundos estão entre as três oscilações que causam maior impacto na variabilidade do processo nas quatro análises. A oscilação de período 15.492 segundos permaneceu entre as três principais nas análises 1 e 2, enquanto que a oscilação de período 8.635 segundos apareceu entre as três principais no dia 3 e a oscilação de 12.064 segundos apareceu como uma das principais no dia 4.

Com relação ao CVE acumulado para as três principais oscilações, verifica-se que a oscilação de período 1.778 segundos foi a que mais impactou na variabilidade dos sinais nos dias 2, 3 e 4, indicando que ela deve ser analisada de forma prioritária pela equipe de operação. Verifica-se ainda que o CVE acumulado para essa oscilação cresceu ao longo dos quatro dias analisados.

O resultado mais detalhado da aplicação do algoritmo sobre os 4 dias é mostrado na Figura 4.19, que apresenta as detecções efetuadas nos 32 sinais (círculos em azul) e as divisões efetuadas para agrupamento dos períodos detectados (linhas horizontais em verde) para as quatro análises, e na Figura 4.20, que apresenta o CVE acumulado para cada grupo de oscilações. Os gráficos obtidos para o dia 1 são mostrados novamente a fim de facilitar a visualização da evolução dos resultados ao longo dos quatro dias analisados.




Figura 4.19. Períodos detectados em cada um dos 32 sinais para os quatro dias.




Figura 4.20. CVE de cada grupo de oscilações detectado para os quatro dias.

A Figura 4.21 apresenta o CVE calculado em cada sinal para as três oscilações principais nos quatro dias. A partir dessa figura é possível perceber que as oscilações detectadas nos sinais 19, 20, 25 e 26 apresentaram CVEs mais elevados que as outras oscilações ao longo dos quatro dias. Já o sinal 22 apresentou a detecção de uma oscilação de CV elevado nos dias 2 e 3, enquanto que a detecção no sinal 21 teve destaque no dia 4. A partir dessas análises, recomenda-se que os sinais 19, 20, 25 e 26 sejam analisados de forma prioritária pela equipe de operação da planta, já que as oscilações apresentadas nesses sinais apresentaram CVE elevado e persistiram ao longo dos quatro dias analisados.

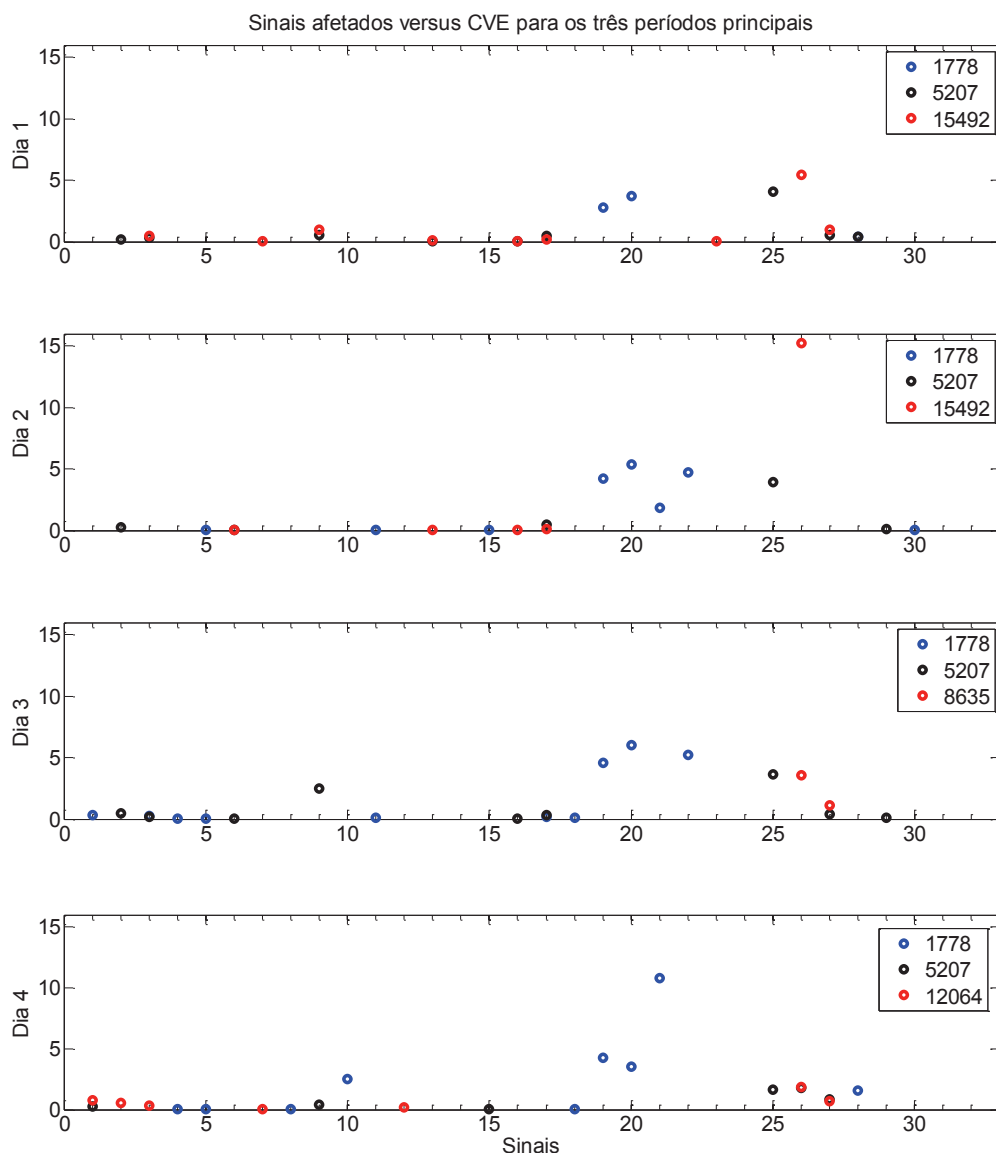


Figura 4.21. CVE para as três oscilações principais durante os quatro dias.

A título de exemplo, os sinais 20 e 25 são mostrados na Figura 4.22 ao longo dos quatro dias. No sinal 20, verifica-se visualmente a presença de uma oscilação de amplitude praticamente constante ao longo de todo o período analisado. Já no sinal 25, também é possível verificar a presença de atividade oscilatória, que é mais pronunciada nos três primeiros dias. No fim do terceiro dia, a amplitude dessa oscilação diminui e posteriormente um distúrbio não oscilatório aparece no sinal. Essa variação na amplitude da oscilação faz com que o CVE também diminua, conforme pode ser visto ao se comparar os quatro gráficos apresentado na Figura 4.21.






Figura 4.22. Sinais 20 e 25 no tempo ao longo dos quatro dias analisados.

## 5 CONCLUSÕES

Neste trabalho, quatro algoritmos de detecção foram comparados a partir de sua aplicação sobre sinais reais de uma planta industrial com múltiplas frequências de oscilação, presença de ruídos e distúrbios, e oscilações de diferentes amplitudes. Verificou-se que após a aplicação da estratégia de configuração dos métodos descrita neste trabalho, os quatro métodos detectaram as oscilações que contribuíram de forma mais significativa para o aumento da variabilidade nos sinais de processo analisados. Durante a configuração dos métodos, verificou-se que o ajuste dos parâmetros individuais do método ACF se mostrou mais simples do que nos outros métodos, já que os efeitos de seus ajustes resultam na seleção ou não de picos nas PSDs dos sinais, que podem ser facilmente visualizados em gráficos auxiliares.

Os ajustes dos parâmetros relacionados ao pré-tratamento (pré-filtragem e tratamento de vazamento espectral), comuns a todos os métodos, se mostraram muito importantes e são feitos facilmente observando as PSDs e os sinais no tempo. Entretanto, a aplicação dos filtros de pré-tratamento sobre sinais contendo *outliers* e distúrbios acentuados pode resultar na inclusão de uma dinâmica oscilatória de baixa frequência que pode levar a falsas detecções pelos métodos. Este trabalho propôs uma metodologia com a finalidade de selecionar apenas segmentos de dados livres de distúrbios não oscilatórios, que se mostrou adequada a partir de sua aplicação sobre um conjunto de 32 sinais pertencentes a um mesmo processo industrial.

Para quantificar a variabilidade ocasionada por cada oscilação identificada foi proposta a utilização da medida Coeficiente de Variação (CV), expresso pela relação desvio padrão/média, e que é usado para analisar a dispersão do sinal em torno de seu valor médio. O CV foi usado como um artifício de caráter gerencial para reduzir a quantidade de sinais que devem ser verificados. Este trabalho propõe que os três grupos de oscilações que apresentarem o maior CV acumulado sejam tratados de forma prioritária pela equipe de operação da planta, já que a resolução desses problemas resultará em ganhos consideráveis na redução da variabilidade do conjunto de sinais monitorados.

O método ACF foi aplicado sobre janelas de dados sequenciais com o objetivo de avaliar a repetibilidade dos resultados obtidos em análises sucessivas. Foi verificado que dois grupos de oscilações figuraram entre as três oscilações que causaram maior impacto na variabilidade nas quatro análises sucessivas realizadas. Baseado na experiência do autor, é proposto que os

métodos sejam configurados de acordo com as características dos sinais a serem analisados. As análises periódicas subsequentes não requerem novos ajustes, pois a dinâmica do processo muda muito pouco.

## 6 REFERÊNCIAS BIBLIOGRÁFICAS

BRILLINGER, D.R., **Time series: data analysis and theory**. 2ª ed. San Francisco: Holden-Day, 1981.

CHOUDHURY, M.A.A.S.; KARIWALA, V.; THORNHILL, N. F.; DOUKE, H.; SHAH, S.L.; TAKADA, H.; FORBES, J.F. Detection and Diagnostics of Plant- Wide Oscillations. **Canadian Journal of Chemical Engineering**, v. 85, p. 208-219, February 2007.

COOLEY, J. W.; LEWIS, P. A.; WELCH, P. D. The application of the fast fourier transform algorithm to the estimation of spectra and cross-spectra. **Journal of Sound and Vibration**, v. 12, p. 339–352, July 1970.

GULHAR, M.; KIBRIA, B. M. G.; ALBATINEH, A. N.; AHMED, N. U. A comparison of some confidence intervals for estimating the population coefficient of variation: a simulation study. **Statistics and Operations Research Transactions**, v. 36, n. 1, p. 45-68, January-June 2012.

HANNAN E. J. **Multiple Time Series**. New York: Wiley, 1970.

HORCH, A.; THORNHILL, N. F.; SEBORG, D.; LAING, D.; GRIMBLE, M. J.; MAJECKI, P.; XIA, H.; BOLL, M.; NOHR, M.; CORSI, S.; BANNAUER, M.; ZIMMER, G. Benchmarking control loop with oscillation and stiction. In: ORDYS, A.; UDUEHI, D.; JOHNSON, M. A. (Eds.). **Process control performance assessment: From theory to implementation**. Londres: Springer Londres, 2007.

HURRI, J.; GÄVERT, H.; SÄRELÄ, J.; HYVÄRINEN, A. **The FastICA package for MATLAB**. Disponível em: <http://www.cis.hut.fi/projects/ica/fastica/> Acesso em: 20 de jan. 2016.

HYVÄRINEN, A.; OJA, E. Independent components analysis: Algorithms and applications. **Neural Networks**, v. 13, n. 4-5, p. 411-430, May-June (2000).

JIANG, H.; CHOUDHURY, M. A. A. S.; SHAH, S. L. Detection and diagnosis of plant-wide oscillations from industrial data using the spectral envelope method. **Journal of Process Control**, v. 17, p. 143-155, February 2007.

KARRA, S.; KARIM, M. N. Comprehensive methodology for detection and diagnosis of oscillatory control loops. **Control Engineering Practice**, v. 17, n. 8, p. 939-956. August 2009.

KOOPMANS, L. H. The Spectral Analysis of Time Series. In: BIRNBAUM, Z. W.; LUKACS, E. (Eds). **Volume 22 of Probability and mathematical statistics – A series of monographs and textbooks**. California: Academic Press, 1995.

LI, X.; WANG, J.; HUANG, B.; LU, S. The DCT-based oscillation detection method for a single time series. **Journal of Process Control**, v. 20, n. 5, p. 609-617. June 2010.

LJUNG, L. System identification toolbox 7: Getting started guide. Massachusetts: The MathWorks, 2010.

MCDUGALL, A.; STOFFER, D.; TYLER, D. Optimal transformations and the spectral envelope for real-valued time series. **Journal Statistical Planning and Inference**. v. 57, p. 195-214, February 1997.

MUNARO, C. J.; VIEIRA JUNIOR., R.; SILVEIRA, M. L.; TARGA, P. E. A. Detection of oscillations on highly disturbed industrial plants. **20th IFAC World Congress**. Submitted, 2017.

SHINSKEY, D. How good are your controller in absolute performance and robustness? **Measurements & Control**, v. 23, p. 114-120, December 1990.

SHUMWAY, R. H. **Applied Statistical Time Series Analysis**. New Jersey: Prentice-Hall, 1988.

TECK, T. W.; KIONG, T. C.; SAMAVEDHAM, L.; KARIWALA, V. Comparison of plant-wide oscillation detection methods. **International Conference on Control Applications**, Singapore, p. 964-969, October 2007.

THORNHILL, N. F.; HÄGGLUND, T. Detection and diagnosis of oscillation in control loops. **Control Engineering Practice**, v. 5, n. 10, p. 1343-1354, October 1997.

THORNHILL, N. F.; SHAH, S. L.; HUANG, B.; VISHNUBHOTLA, A. Spectral principal component analysis of dynamic process data. **Control Engineering Practice**, v. 10, n. 8, p. 833-846, August 2002.

THORNHILL, N. F.; HUANG, B.; ZHANG, H. Detection of multiple oscillations in control loops. **Journal of Process Control**, v. 13, n.1, p. 91-100, February 2003.

UITERT, G. V. Reduction of leakage and increase of resolution in power spectral density and coherence functions. **Nuclear Instruments and Methods**, v. 157, n. 3, p. 583-589, December 1978.

WANG, J.; HUANG, B.; LU, S. Improved DCT-based method for online detection of oscillations in univariate time series. **Control Engineering Practice**, v. 21, n. 5, p. 622-630, May 2013.

XIA, C.; HOWELL, J. Isolating multiple sources of plant-wide oscillations via independent component analysis. **Control Engineering Practice**, v. 13, n. 8, p. 1027-1035, August 2005.

XIA, C.; HOWELL, J.; THORNHILL, N. F. Detecting and isolating multiple plant-wide oscillations via spectral independent component analysis. **Automatica**, v. 41, n. 12, p. 2067-2075, December 2005.