

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**



MARIANA LYRA SILVEIRA

**IMPLEMENTAÇÃO DE MÉTODO DE DETECÇÃO DE
OSCILAÇÕES EM AMBIENTE INDUSTRIAL**

VITÓRIA – ES
12/2016

MARIANA LYRA SILVEIRA

IMPLEMENTAÇÃO DE MÉTODO DE DETECÇÃO DE OSCILAÇÕES EM AMBIENTE INDUSTRIAL

Parte manuscrita do Projeto de Graduação da aluna Mariana Lyra Silveira, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheira Eletricista.

Prof. Dr. Celso J. Munaro
Orientador

MARIANA LYRA SILVEIRA

**IMPLEMENTAÇÃO DE MÉTODO DE DETECÇÃO DE OSCILAÇÕES
EM AMBIENTE INDUSTRIAL**

Parte manuscrita do Projeto de Graduação da aluna **Mariana Lyra Silveira**, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheira Eletricista.

Aprovada em 14 de dezembro de 2016.

COMISSÃO EXAMINADORA:

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

Prof. Ph.D. Teodiano Freire Bastos Filho
Universidade Federal do Espírito Santo - UFES
Examinador

Eng. Paulo Emilio Altoé Targa
Examinador

RESUMO

A presença de oscilações em sistemas de controle pode reduzir a qualidade do produto final, diminuir a vida útil dos equipamentos e até mesmo interromper a operação da planta. Dessa forma, métodos de detecção de oscilação são utilizados em ambientes industriais com o objetivo de identificar e corrigir efeitos nocivos provenientes de comportamentos oscilatórios. Este trabalho discute o método de Detecção e Caracterização de Oscilação, bem como uma metodologia de pré-tratamento para processos fortemente afetados por distúrbios. Também é apresentada a Plataforma de Gerenciamento de Ativos, que visa o monitoramento de sinais provenientes de diversos processos realizados pela empresa Petrobrás, na qual os algoritmos foram implementados. Por fim, apresenta-se o desenvolvimento de um Plug-in nessa plataforma, com a finalidade de detectar oscilações em dados de processos industriais.

ABSTRACT

The presence of oscillations in control loops may reduce the quality of the final product, decrease the lifetime of equipments and even interrupt the plant operation. Thus, oscillation detection methods are used in industrial environments with the objective of identifying harmful effects produced by oscillatory behaviors. This work discusses the method Detection and Characterization of Oscillations, as well as a pre-treatment methodology for highly disturbed industrial plants. The Asset Management Platform is shown, aiming to monitor several processes carried out by Petrobrás, in which the algorithms were implemented. Finally, the development of a Plug-in into this platform is also introduced, in order to detect oscillations in industrial process data.

LISTA DE FIGURAS

Figura 1 – Fluxograma do método ODC	14
Figura 2 – ACF e PSD de um ruído branco (2.a) e de um sinal oscilatório ($x(t) = 0,5\text{seno}(0,1t) + 0,2\text{randn}$).....	16
Figura 3 – Aplicação da transformada rápida de Fourier a um sinal $x(k) = \text{seno}(2\pi 10) + 0,4 * \text{seno}(2\pi 7)$	17
Figura 4 – Exemplificação de uma janela gaussiana (meio) e do produto de W_g por $x(k)$...	19
Figura 5 – Fft de $xk = \text{seno}2\pi 10 + 0,4 * \text{seno}2\pi 7$, obtida por meio da utilização de uma janela Retangular uma janela gaussiana ($\alpha = 5$).....	20
Figura 6 – Efeito do aumento de α fixando-se ϵp em 0,1	21
Figura 7 – Exemplificação da obtenção das bandas de frequências por meio da PSD normalizada de um sinal coletado em uma malha de controle de temperatura.	22
Figura 8 – Limiares dos filtros para as bandas de frequência exibidas na Figura 7	24
Figura 9 – Sinais de processo típicos de plantas em UEPOG	26
Figura 10 – Componentes oscilatórias introduzidas após a filtragem	27
Figura 11 – PSD do sinal original e PSD do sinal filtrado	28
Figura 12 – Sinal exemplo para a explicação das etapas do passo a passo	29
Figura 13 – Histogramas de xt utilizando $nb = 10$, $nb = 30$ e $nb = 50$	30
Figura 14 – Classes agrupadas atribuindo $limiar = 2,5 \%$	31
Figura 15 – Amostras selecionadas nas etapas 3 (cima) e 4 (baixo) do algoritmo.....	32
Figura 16 - Amostras selecionadas nas etapas 4 (cima) e 5 (baixo) do algoritmo	33
Figura 17 – Resultado final fornecido pelo algoritmo de pré-tratamento	33
Figura 18 – PSDs do sinal original, do sinal filtrado e do sinal pré-tratado.....	34
Figura 19 – Sinal no tempo e sua PSD normalizada.	36
Figura 20 – Agrupamento das oscilações utilizando histogramas com 3 classes (incorreto), 10 classes e 20 classes	38
Figura 21 – Etapas envolvidas no funcionamento do Plug-in	40
Figura 22 – Exemplo ilustrativo de uma análise.	40
Figura 23 - Fluxo de dados durante a execução de um plug-in PGA utilizando uma rotina MATLAB	43
Figura 24 – Variáveis de processo do sistema de processamento de óleo de uma UEPOG...	47
Figura 25 – Dados retidos pelo algoritmo de seleção de segmentos (em vermelho)	48

Figura 26 – Percentual de retenção por sinal.....	48
Figura 27 – Percentual médio de dados retidos por dia.....	49
Figura 28 – Oscilações detectadas durante o intervalo analisado.....	50
Figura 29 – CVE das oscilações agrupadas durante os 4 dias (são considerados apenas os grupos com os 3 maiores CVEs)	51
Figura 30 – Oscilações detectadas nos 32 sinais analisados durante os 4 dias.....	52
Figura 31 – Sinais de processo 9, 11, 18 e 29 coletados durante o segundo dia	52
Figura 32 – Sinal 25 durante os 4 dias analisados. Foram consideradas somente as amostras selecionadas pelo algoritmo de seleção de segmentos	54
Figura 33 – Trechos oscilatórios dos sinais 4, 5, 19 e 20 coletados durante todos os Dias 1, 2 e 3.....	54
Figura 34 – Análise proposta para o Plug-in desenvolvido.....	55
Figura 35 – Período das principais oscilações.....	57
Figura 36 – CVE das principais oscilações	58
Figura 37 - Percentual de retenção calculado em todas as análises.....	59

LISTA DE ABREVIATURAS E SIGLAS

ACF	Função de Auto Correlação
CV	Coeficiente de Variação
CVE	Coeficiente de Variação ponderado pela energia
DCT	Transformada Discreta de Cosseno
ICA	Análise por Componentes Independentes
ODC	Detecção e Caracterização de Oscilação
PGA	Plataforma de Gestão de Ativos
PSD	Densidade Espectral de Potência
UEPOG	Unidades Estacionárias de Produção de Óleo e Gás

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Apresentação e justificativa da pesquisa	10
1.2	Objetivo e estrutura do trabalho	12
2	DETECÇÃO DE OSCILAÇÕES.....	13
2.1	Pré-tratamento	13
2.2	Função de autocorrelação	13
2.3	Densidade Espectral de Potência.....	15
2.4	Determinação das frequências dominantes	19
2.4.1	Limiar de potência	20
2.4.2	Limiar de energia	22
2.4.3	Filtragem de frequências.....	23
2.5	Obtenção dos sinais ACF por meio da PSD filtrada	23
2.6	Períodos de oscilação	24
2.7	Índice de regularidade	25
2.8	Agrupamento de frequências.....	25
3	SEGMENTAÇÃO DE DADOS E AGRUPAMENTO DE OSCILAÇÕES DE MAIOR ENERGIA	26
3.1	Pré-tratamento dos dados	26
3.1.1	Filtro de pré-tratamento	27
3.1.2	Seleção de segmentos de dados	28
3.1.2.1	Cálculo do histograma	29
3.1.2.2	Seleção da classe de maior número de elementos	30
3.1.2.3	Agrupamento de classes adjacentes.....	30
3.1.2.4	Inclusão de elementos com valor superior a $\mu_{xtt} \pm nstd * \sigma(xtt)$	32
3.1.2.5	Eliminação de trechos com descontinuidades	33
3.1.2.6	Resultados da rotina de pré-tratamento	34
3.2	Quantificação do impacto das oscilações	34
3.3	Agrupamento de oscilações presentes em diferentes sinais	36
4	IMPLEMENTAÇÃO EM AMBIENTE INDUSTRIAL.....	39
4.1	PGA.....	39
4.1.1	Ativo de Processo	39
4.1.2	Plug-in.....	39

4.1.3	Análise	40
4.1.4	Visualizador de Resultados	41
4.1.5	Relatório Gerencial	41
4.2	Desenvolvimento dos Plug-ins	42
4.3	Plug-in de detecção de oscilação	43
4.3.1	Entradas	43
4.3.2	Saídas	44
4.3.2.1	Visualizador de Resultados.....	44
4.3.2.2	Relatório Gerencial	45
5	 APLICAÇÃO AOS DADOS REAIS	46
5.1	Dados provenientes de um processo industrial real	46
5.2	Seleção de segmentos de dados	47
5.3	Validação do algoritmo de detecção de oscilações	49
5.4	Apresentação dos resultados no PGA	55
6	 CONCLUSÕES E TRABALHOS FUTUROS.....	60
7	 BIBLIOGRAFIA	62

1 INTRODUÇÃO

1.1 Apresentação e justificativa da pesquisa

Na maioria dos processos industriais as condições de operação estão sujeitas a mudanças ao longo do tempo. Essa dinâmica é tratada pelas malhas de controle, que conferem estabilidade ao sistema e atendem às especificações necessárias ao padrão de qualidade do processo. Nesse contexto, muitos estudos são realizados a fim de avaliar a eficiência dos sistemas de controle.

Segundo Jelali e Huang (2009, p. 61), malhas de controle com comportamentos oscilatórios não indicam apenas uma variabilidade irregular no processo, mas também a possível existência de problemas severos que podem comprometer o desempenho da produção. De acordo com Karra e Karim (2009), esse comportamento oscilatório pode reduzir a qualidade do produto final, diminuir a vida útil dos equipamentos e até mesmo interromper a operação da planta. Outro estudo, realizado por Shinskey (1990), afirmou que a presença de uma oscilação em uma malha de controle gera um aumento no custo de produção proporcional à amplitude dessa oscilação.

Na maioria dos casos, esse comportamento oscilatório ocorre devido à presença de atrito nas válvulas de controle da planta. Controladores com ganhos excessivamente elevados e distúrbios oscilatórios também são apontados como causas comuns de oscilações em um processo industrial (Jelali e Huang, 2009, p. 61). Dessa forma, métodos de detecção de oscilações foram elaborados com o objetivo de corrigir os problemas mencionados e, conseqüentemente, tornar os processos industriais mais eficientes e rentáveis.

Thornhill et al. (2003) utilizaram a função de auto correlação (ACF - Autocorrelation Function) das variáveis de processo para identificar os comportamentos oscilatórios da planta. Esse método possui a importante característica de atenuar o ruído e preservar as frequências originais das oscilações no tempo. Posteriormente, propostas de melhorias foram feitas por Karra e Karim (2009), onde foi analisada a Densidade Espectral de Potência dos sinais (PSD - *Power Spectral Density*) foi analisada de forma mais detalhada, a fim de melhorar a metodologia de identificação e filtragem dos períodos das oscilações.

O método de Análise por Componentes Independentes (ICA – *Independent Component Analysis*), fundamentado por Li e Wang (2002), também foi utilizado para a detecção de oscilações em malhas de controle (Xia e Howell, 2005). Mais recentemente, Jiang et al. (2007) fundamentaram o método Envelope Espectral (SE – *Spectral Envelope*), cujo objetivo consiste em detectar oscilações de um processo e categorizar variáveis com propriedades espectrais semelhantes.

Li et. al. (2010) utilizaram pela primeira vez a Transformada Discreta de Cosseno (DCT) com o objetivo de identificar oscilações. Posteriormente, Wang et. al (2013) aperfeiçoaram essa técnica, cuja ideia principal é isolar as diferentes componentes de frequência das séries temporais via DCT e detectar as oscilações verificando a regularidade dos cruzamentos por zero dessas componentes isoladas.

Vieira Junior et al. (2016) compararam todos os métodos anteriormente citados, aplicando-os aos dados coletados de plantas em Unidades Estacionárias de Produção de Óleo e Gás (UEPOG). Os autores comprovaram que os resultados obtidos por meio dos métodos ODC e ICA foram mais consistentes. Além disso, essas duas técnicas possuem parâmetros que são mais facilmente configurados em comparação às demais.

A principal motivação deste trabalho está fundamentada na importância de identificar oscilações em um processo industrial, pois essas podem ser originadas por um problema severo e demandar ações corretivas. Neste trabalho será utilizado o método ODC proposto por Karra e Karim (2009) para a detecção de oscilações em plantas situadas em uma UEPOG. O algoritmo desenvolvido estará disponível para uso em ambiente industrial por meio de uma plataforma de supervisão de ativos de processo, denominada PGA. Essa plataforma permite que o usuário processe dados provenientes de malhas de controle, utilizando blocos que executam funções específicas, como por exemplo, extração da média, cálculo da densidade espectral, cálculo da função de autocorrelação, entre outras funções. Sendo assim, basta que o usuário conheça o propósito de cada bloco, não necessitando entender profundamente sobre o seu funcionamento.

Os algoritmos apresentados neste trabalho serão transformados em um bloco de processamento de dados dentro da PGA, assim poderão ser facilmente acessados por qualquer

usuário da plataforma. Também são apresentados os testes realizados a partir do bloco desenvolvido. Adicionalmente, foram analisadas malhas de controle com comportamentos oscilatórios situadas em um sistema de processamento de óleo de uma UEPOG. As malhas foram estudadas durante o período de 01/05/2016 a 15/07/2016.

Vale ressaltar que este trabalho foi executado dentro do contexto do Projeto de Pesquisa intitulado “Diagnóstico da Causa Raiz de Oscilações e Perturbações em Unidades Estacionárias de Produção de Óleo e Gás”, realizado entre a Petrobrás e o Departamento de Engenharia Elétrica da UFES.

1.2 Objetivo e estrutura do trabalho

Este trabalho propõe o desenvolvimento de um bloco de execução, cuja finalidade é identificar a presença de comportamentos oscilatórios em sinais de processo. Esse será instalado na PGA, onde poderá ser utilizado para monitorar qualquer sistema de controle situado em uma UEPOG.

O trabalho está organizado conforme a seguinte estrutura: no capítulo 2 é discutido o método de detecção de oscilação adotado. O capítulo 3 apresenta a metodologia utilizada para o pré-tratamento dos sinais, uma vez que esses são fortemente afetados por distúrbios não oscilatórios e a utilização de filtros pode introduzir componentes oscilatórias indesejáveis. O capítulo 4 apresenta a PGA, bem como o processo de conversão do algoritmo desenvolvido para um bloco dentro da mesma. O Capítulo 5 apresenta os resultados obtidos por meio de um estudo de caso aplicado aos dados de um processo industrial real. Finalmente, as conclusões finais e sugestões para trabalhos futuros são apresentadas no Capítulo 6.

2 DETECÇÃO DE OSCILAÇÕES

O método Detecção e Caracterização de Oscilação (ODC – Oscillation Detection and Characterization), proposto por Karra e Karim, (2009), utiliza a Função de Autocorrelação (ACF) para avaliar o comportamento oscilatório de um sinal. O benefício dessa ferramenta matemática consiste na atenuação do impacto do ruído presente no sinal analisado (Jelali e Huang, 2009, p. 77). O método citado também utiliza a Densidade Espectral de Potência (PSD) para identificar as frequências das oscilações dominantes.

As próximas seções deste capítulo descrevem de forma mais detalhada a teoria necessária para o entendimento do método, cujas etapas são enumeradas a seguir:

- 1) Fazer o pré-tratamento do sinal;
- 2) Calcular a ACF do sinal pré-tratado;
- 3) Calcular a PSD do sinal autocorrelacionado;
- 4) Determinar as bandas de frequência com energia acima do limiar ε_p ;
- 5) Calcular a ACF dos sinais filtrados por meio da Transformada Inversa de Fourier;
- 6) Calcular os períodos de oscilação T_p ;
- 7) Verificar se as oscilações têm período regular;

A Figura 1 exibe o fluxograma das etapas do método de detecção de oscilação.

2.1 Pré-tratamento

Essa etapa será discutida na seção 3.1.2.1.

2.2 Função de autocorrelação

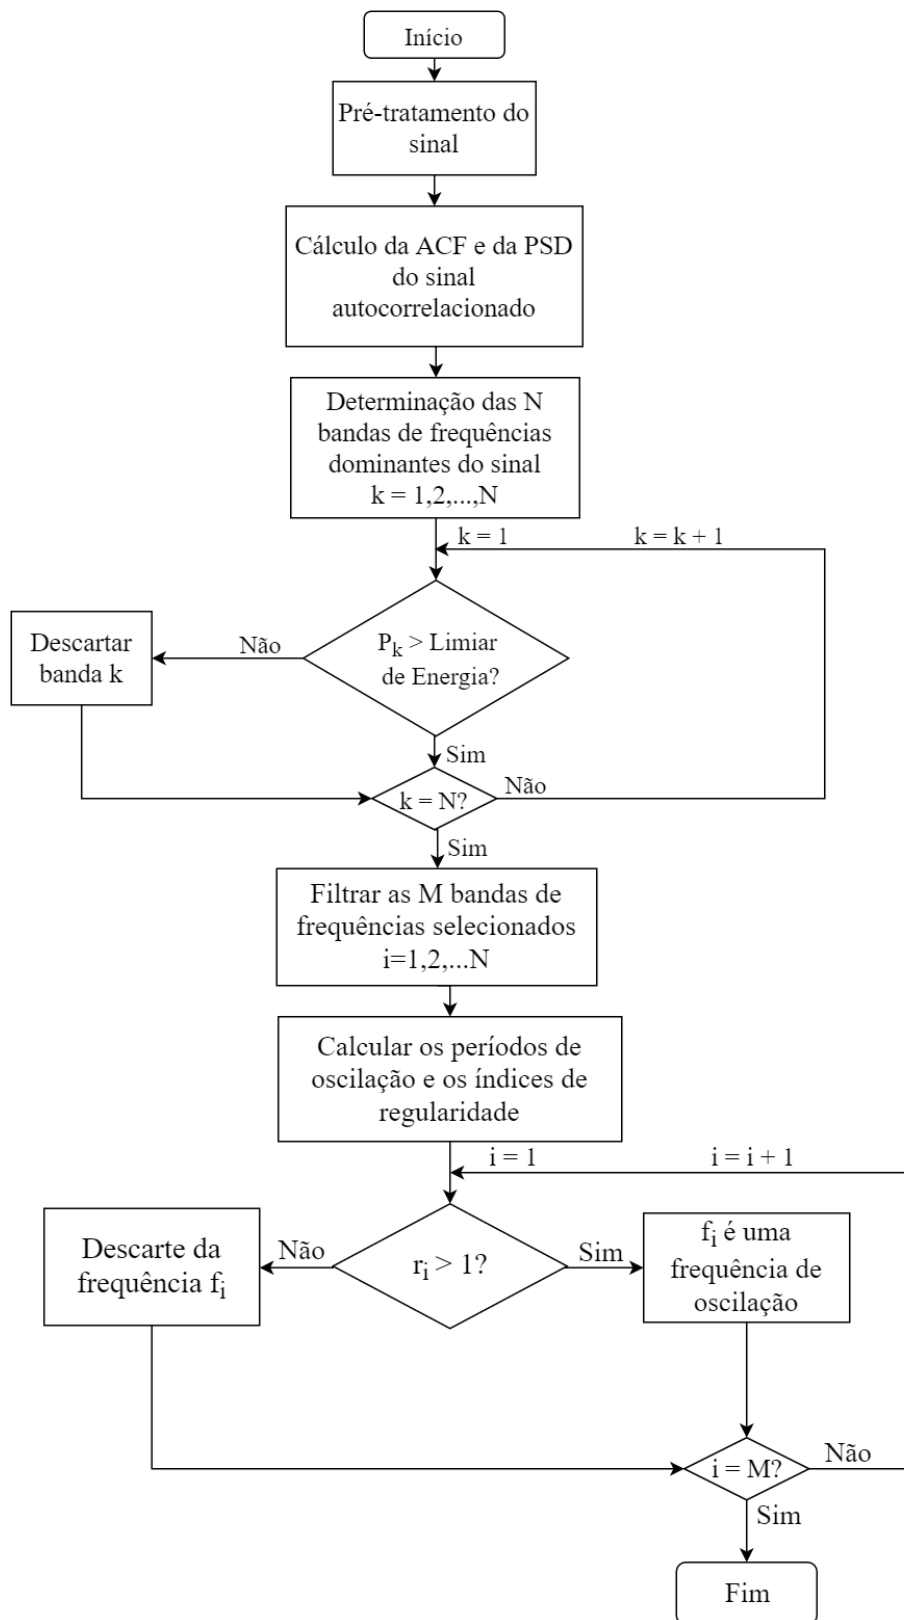
A dependência estatística de uma série-temporal de dados pode ser caracterizada pela função de autocorrelação amostral (ACF), que é expressa por

$$r_{xx}(k) = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}, \quad (1)$$

onde x_t corresponde à medição feita no instante de tempo $t = 0, 1, 2 \dots$, \bar{x} representa a média amostral das n amostras e k corresponde ao número do atraso. Cada coeficiente de

autocorrelação r_{xx} está contido no intervalo $[-1,1]$. A ACF de um sinal com comportamento oscilatório também é oscilatória.

Figura 1 – Fluxograma do método ODC



2.3 Densidade Espectral de Potência

A Densidade Espectral de Potência (PSD, em inglês) descreve a distribuição de potência ao longo das componentes de frequência que compõem o sinal analisado.

Matematicamente, a PSD é a Transformada de Fourier da função de autocorrelação, $r_{xx}(k)$, de um sinal. Dessa forma, em tempo discreto, o espectro de potência é obtido por meio de

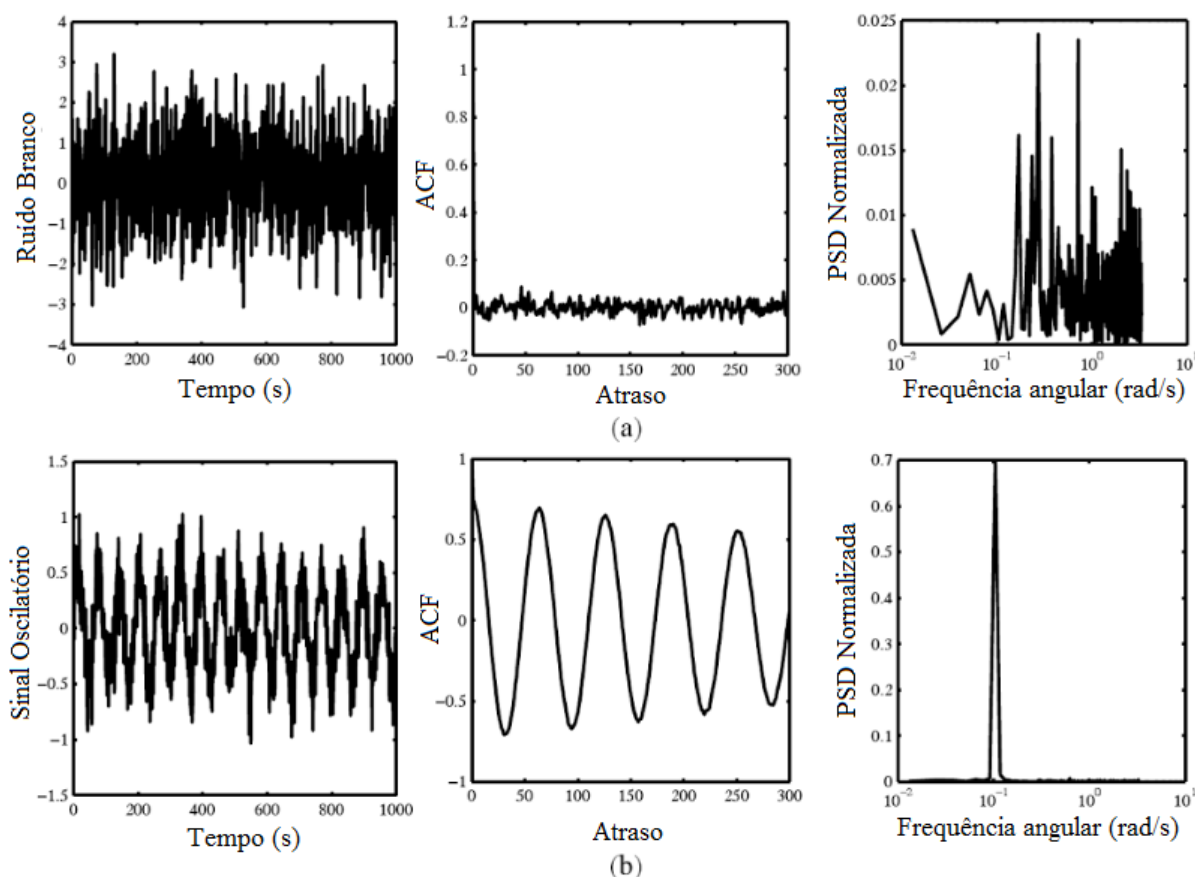
$$S_x(f) = \sum_{k=-\infty}^{\infty} r_{xx}(k)e^{-2\pi jfk}. \quad (2)$$

No método ODC utiliza-se a PSD normalizada, dada por:

$$S_{Nx}(f) = \frac{S_x(f)}{\sum S_x(f)}. \quad (3)$$

A Figura 2.a (esquerda) ilustra um ruído branco. Pode-se visualizar na Figura 2.b (meio) que a ACF desse sinal é praticamente nula para atrasos maiores do que zero. Nota-se, também, que a PSD normalizada é uniformemente distribuída em toda faixa de frequência. Já a Figura 2.b (direita) mostra um sinal oscilatório ruidoso com uma frequência de oscilação dominante. A ACF desse sinal (esquerda) oscila com a mesma frequência. Pode-se notar que a Função de Autocorrelação é pouco afetada pelo ruído. A PSD normalizada do sinal está ilustrada na Figura 2 (meio). É possível visualizar que a potência do sinal é muito maior na frequência de oscilação dominante, o que resulta em um pico bem definido.

Figura 2 – ACF e PSD de um ruído branco (2.a) e de um sinal oscilatório ($x(t) = 0,5\text{seno}(0,1t) + 0,2\text{randn}$)



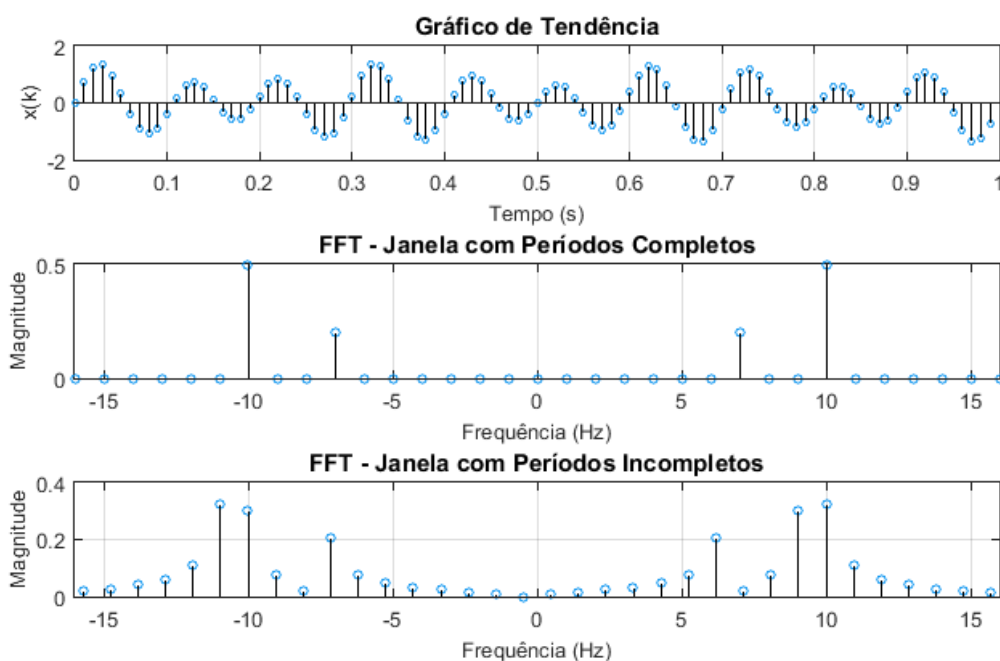
Fonte: JELALI; HUANG, 2009, p. 66.

Neste trabalho a Transformada de Fourier de Tempo Discreto (DTFT) do sinal autocorrelacionado foi calculada por meio da Transformada Rápida de Fourier (FFT), uma vez que essa reduz o efeito do ruído no espectro de potência. (Depizzol, 2011).

O resultado da transformada de Fourier para um sinal oscilatório com uma única frequência dominante de oscilação é dado por um único pico de potência no espectro, desde que esse sinal seja amostrado com um número inteiro de períodos. A aplicação de uma janela inadequada ao sinal amostrado pode selecionar números não inteiros de períodos de oscilação, o que causa mudanças no espectro original. Esse evento, conhecido como vazamento espectral, introduz picos espúrios de frequência no espectro de potência, influenciando e comprometendo os resultados finais do método de detecção de oscilação. Esses picos espúrios podem ser confundidos com os picos das frequências dominantes, ocasionando a detecção de um elevado número de frequências de oscilação. Além disso, o vazamento espectral também dificulta a identificação de oscilações que possuem pouca energia.

A Figura 3 exemplifica uma situação suscetível ao vazamento espectral. O primeiro gráfico de cima para baixo demonstra o sinal discreto $x(k) = \text{seno}(2\pi 10t) + 0,4 * \text{seno}(2\pi 7t)$. O gráfico do meio ilustra a FFT de $x(k)$, obtida por meio do uso de uma janela com um número inteiro de períodos (para ambas as frequências de oscilações). O terceiro gráfico demonstra o efeito da utilização de uma janela com períodos não inteiros. Nesse caso, nota-se que o vazamento espectral distorceu o resultado original.

Figura 3 – Aplicação da transformada rápida de Fourier a um sinal $x(k) = \text{seno}(2\pi 10) + 0,4 * \text{seno}(2\pi 7)$. O gráfico do meio representa o resultado ideal. O gráfico de baixo demonstra o efeito do vazamento espectral.



Uma vez que a frequência de oscilação de um sinal de processo é desconhecida, não é possível aplicar uma janela de dados com um número inteiro de períodos. Além disso, na maioria dos casos estudados neste trabalho, os sinais analisados possuem mais de uma frequência de oscilação. Dessa forma, não é possível garantir que uma janela possuirá um número inteiro de períodos para todas as oscilações presentes.

A solução mais adotada para minimizar as discontinuidades introduzidas pelo vazamento espectral consiste na utilização de uma janela ponderada (Uitert, 1978). No caso do método ODC, o sinal autocorrelacionado sofrerá um truncamento, representado matematicamente pela multiplicação por uma função $W(k)$, chamada de janela:

$$\rho(k) = r_{xx}(k)W(k). \quad (4)$$

Existem várias janelas que podem ser utilizadas para este fim, no entanto, Depizzol (2011) afirma que a janela de Hamming e a janela gaussiana são as que mostraram melhores resultados para dados coletados na indústria. Foi então proposta a utilização da janela gaussiana para a detecção de oscilações, pois essa pode ser ajustada de forma a reduzir o efeito do vazamento espectral.

A janela gaussiana é expressa por:

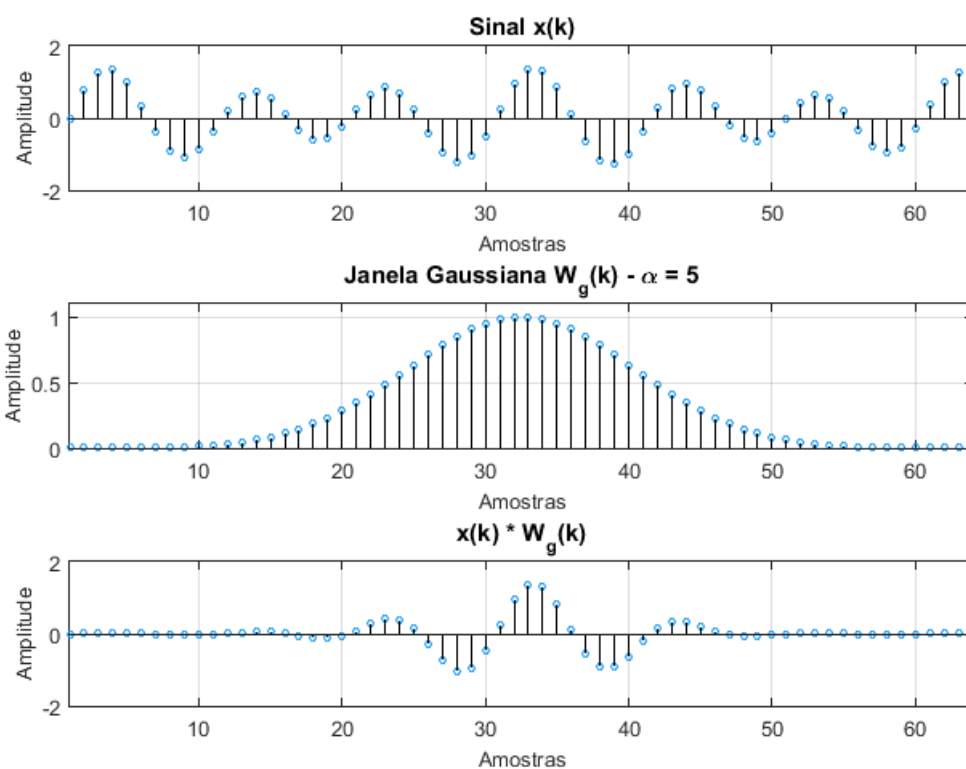
$$W_g(n) = e^{-\frac{1}{2}\left(\alpha\frac{n}{(N-1)/2}\right)^2}, \quad (5)$$

onde $-\frac{N-1}{2} \leq n \leq \frac{N-1}{2}$, sendo que N corresponde ao comprimento da janela.

Quanto maior for o valor de α , menor será o efeito do vazamento espectral. No entanto, o janelamento também atenua a energia das oscilações, comprometendo os resultados do método de detecção de oscilação quando valores de α muito elevados são utilizados. Sendo assim, a escolha de α deve ser feita por meio da avaliação dos espectros de potência dos sinais monitorados. Por verificações empíricas, utilizou-se $5 \leq \alpha \leq 10$ neste trabalho.

A Figura 4 mostra uma janela gaussiana e exibe o resultado da multiplicação de um sinal por W_g . O primeiro gráfico ilustra o sinal $x(k) = \text{seno}(2\pi 10) + 0,4 * \text{seno}(2\pi 7)$, já utilizado anteriormente. Já o gráfico do meio exibe a janela proposta. Por fim, o terceiro gráfico demonstra o efeito da multiplicação por W_g , utilizando $\alpha = 5$.

Figura 4 – Exemplificação de uma janela gaussiana (meio) e do produto de W_g por $x(k)$

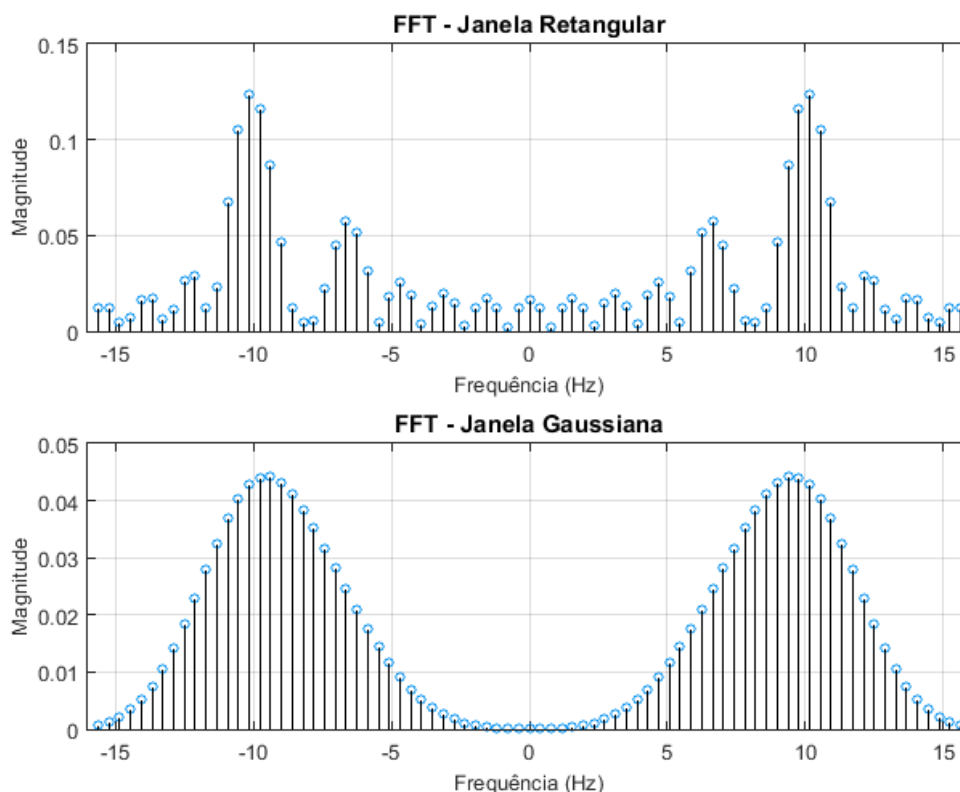


A Figura 5 mostra como a janela gaussiana suaviza as discontinuidades presentes em uma FFT obtida com o uso de uma janela retangular. Novamente, utilizou-se o sinal $x(k) = \text{seno}(2\pi 10) + 0,4 * \text{seno}(2\pi 7)$.

2.4 Determinação das frequências dominantes

Com o objetivo de separar o ruído das frequências dominantes, o método ODC apresenta dois limiares que são aplicados à PSD normalizada no sinal: o limiar de potência e o limiar de energia.

Figura 5 – FFT de $x(k) = \text{seno}(2\pi 10) + 0,4 * \text{seno}(2\pi 7)$, obtida por meio da utilização de uma janela retangular uma janela gaussiana ($\alpha = 5$)



Como é possível visualizar na Figura 5, as frequências de 7 e 10 Hz foram agrupadas em um único pico após o tratamento do vazamento espectral por meio da janela gaussiana. Esse agrupamento não possui efeito prejudicial e o próprio método ODC especifica uma metodologia de agrupamento de oscilações com períodos semelhantes (ver seção 2.8). Vale ressaltar que o objetivo da janela gaussiana é reduzir as descontinuidades introduzidas pelo vazamento espectral, impedindo assim a detecção de um elevado número frequências de oscilação.

2.4.1 Limiar de potência

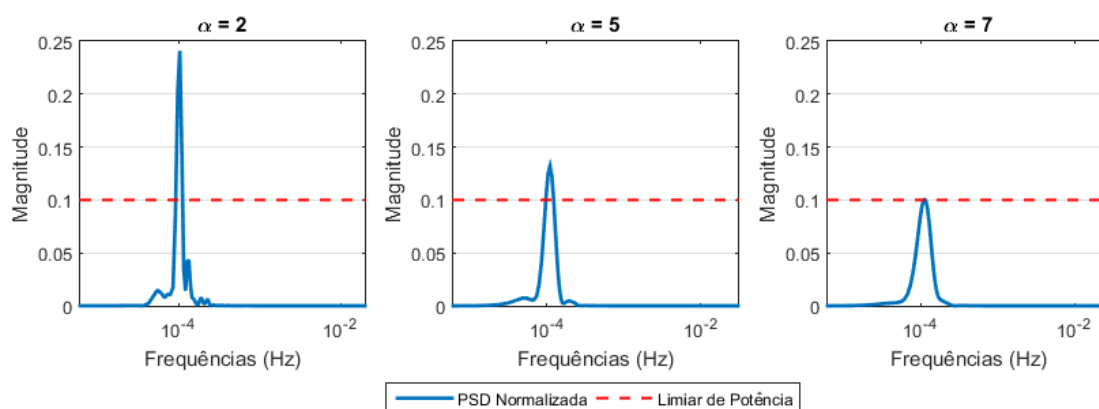
O limiar de potência, denotado por ε_p , classifica as bandas de frequência em $S_{Nx}(f)$, as quais são relevantes para a análise do comportamento oscilatório do sinal. As frequências das bandas selecionadas são determinadas pela intersecção de ε_p com $S_{Nx}(f)$.

O limiar ε_p está associado ao parâmetro α da janela Gaussiana. Como já explicitado na seção anterior, quanto maior for o valor de α , menor será a amplitude dos picos presentes na PSD.

Sendo assim, espectros que possuem um elevado fator de alisamento demandam cautela para a escolha do parâmetro ε_p , a fim de evitar o descarte equivocado de bandas de frequência.

A Figura 6 demonstra a relação entre o alisamento da PSD e o limiar de potência. Variou-se o parâmetro α da janela gaussiana enquanto o limiar ε_p foi mantido fixo em 0,1. O sinal utilizado foi coletado de uma malha de controle de nível. Como é possível visualizar no gráfico da direita, a utilização de $\alpha = 7$ requer a redução do valor de ε_p , caso contrário, a oscilação não será detectada.

Figura 6 – Efeito do aumento de α fixando-se ε_p em 0,1



Em geral, reduzir muito o valor do limiar ε_p não tende a produzir diferenças significativas nos resultados do método de detecção de oscilação. Geralmente, o que ocorre nesses casos é o aumento do número de oscilações descartadas por possuírem energia inferior ao limiar.

Karra e Karim (2009) sugerem a utilização de $\varepsilon_p = 0,1$. Entretanto, Depizzol (2011) constatou que essa nem sempre é uma boa escolha: muitas vezes existem picos bem definidos de oscilações que possuem amplitude inferior a 0,1; assim, caso ε_p fosse definido conforme Karra e Karim, esses picos não seriam detectados pelo método (observar Figura 6, gráfico à direita).

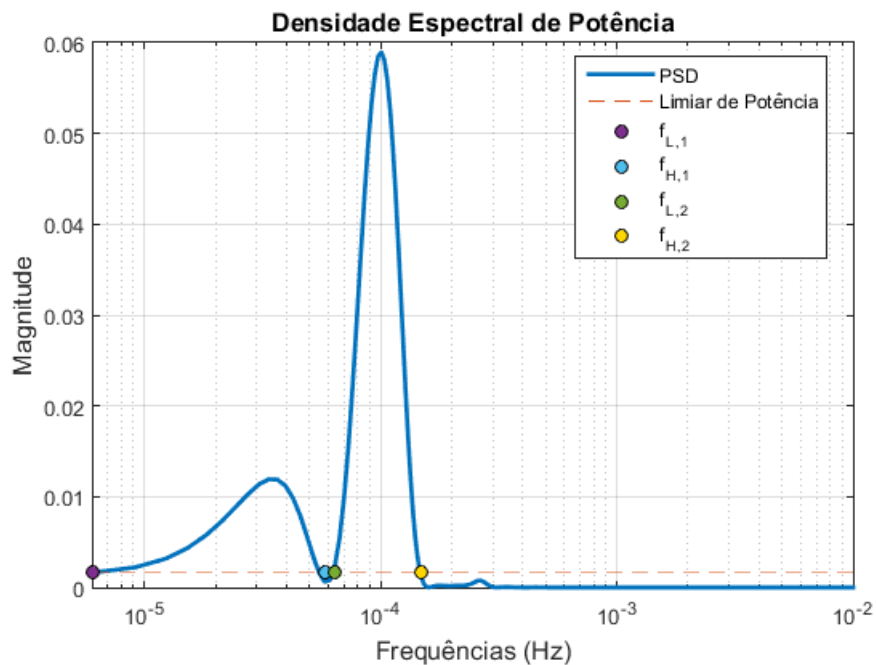
Neste trabalho utilizou-se:

$$\varepsilon_p = \mu_{PSD} + \sigma_{PSD}, \quad (6)$$

onde μ_{PSD} corresponde à média de $S_{Nx}(f)$ (PSD normalizada) e σ_{PSD} corresponde ao desvio padrão de $S_{Nx}(f)$.

A Figura 7 exemplifica a obtenção das bandas de frequência por meio da intersecção entre ε_p e $S_{Nx}(f)$. O gráfico exibe a PSD normalizada de um sinal coletado em uma malha de temperatura, na qual se utilizou a janela gaussiana ($\alpha = 5$). A oscilação de menor frequência é seccionada por ε_p em $f_{L,1}$ e $f_{H,1}$. Analogamente, a oscilação de maior frequência é seccionada por ε_p em $f_{L,2}$ e $f_{H,2}$.

Figura 7 – Exemplificação da obtenção das bandas de frequências por meio da PSD normalizada de um sinal coletado em uma malha de controle de temperatura.



2.4.2 Limiar de energia

O limiar de energia ε_e verifica a energia das bandas selecionadas, descartando aquelas com energia inferior ao limiar.

Segundo o teorema de Parseval (Koopmans, 1995), a energia de uma oscilação é calculada por meio da soma das potências em $S_{Nx}(f)$ das componentes de frequência abrangidas por $[f_L, f_H]$:

$$P = \sum_{f_L}^{f_H} S_{Nx}(f). \quad (7)$$

O cálculo da energia é realizado para todas as oscilações com potência superior ao limiar de potência. Baixos valores de P indicam que o sinal não possui atividade oscilatória significativa na banda selecionada. Neste trabalho adotou-se $\varepsilon_e = 0,1$.

2.4.3 Filtragem de frequências

Caso existam múltiplas frequências de oscilação com energia superior ao limiar, os grupos formados pelos picos das frequências dominantes são filtrados por meio de filtros passa-banda. Esses filtros são aplicados diretamente à PSD normalizada do sinal. Se $P < \varepsilon_e$, a banda de frequência não deve ser considerada para a filtragem.

Suponha que o método de detecção de oscilação identificou a presença de M bandas de frequência na PSD. As bordas dos M filtros estarão centralizadas entre cada par das bandas de frequência selecionadas por ε_p , havendo duas exceções a essa regra: a borda inferior do filtro utilizado para filtrar a menor frequência dominante deverá estar centralizada entre a frequência nula e $f_{L,1}$; já a borda superior do filtro utilizado para filtrar a maior frequência dominante deverá estar centralizada entre $f_{H,M}$ e a frequência determinada por

$$\min\left(2f_{H,M}, \frac{w_s}{2}\right),$$

onde w_s corresponde à frequência de amostragem do sinal.

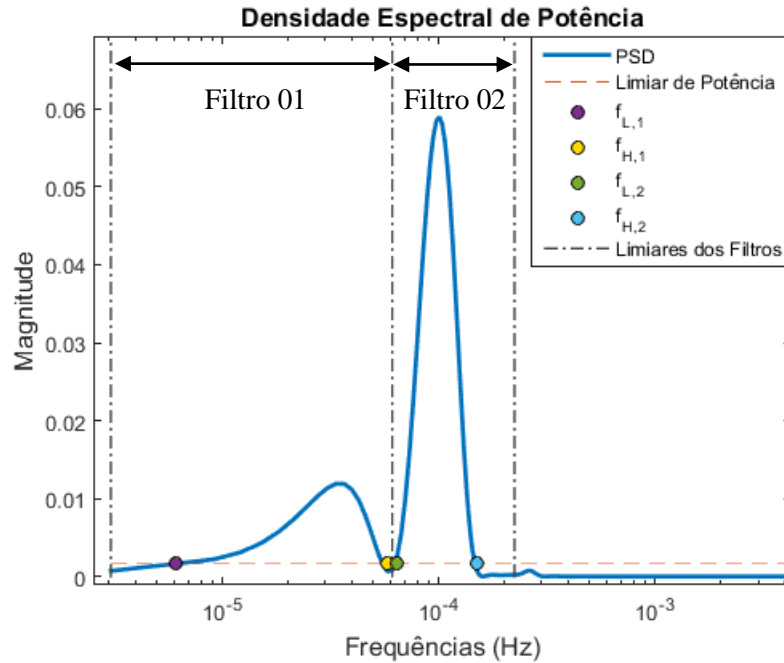
A Figura 8 demonstra os limiares dos filtros para as bandas de frequência exibidas na Figura 7.

2.5 Obtenção dos sinais ACF por meio da PSD filtrada

Após a filtragem das múltiplas frequências de oscilação, deve-se avaliar se os sinais autocorrelacionados apresentam regularidade dos períodos. Para tanto, verificam-se os cruzamentos por zero. O método de detecção de oscilação considera somente as frequências de oscilação que possuem oito ou mais cruzamentos por zero.

A ACF é obtida por meio da transformada inversa de Fourier dos sinais filtrados.

Figura 8 – Limiares dos filtros para as bandas de frequência exibidas na Figura 7



2.6 Períodos de oscilação

Os períodos de oscilação (T_p) podem variar em torno de um valor médio, devido à presença de ruídos e distúrbios no processo. Se a oscilação for causada por um evento aleatório, seu período será descrito por um largo intervalo de valores, enquanto os períodos de uma verdadeira oscilação são distribuídos em intervalos mais estreitos.

Os períodos T_p são definidos pelo dobro do intervalo de tempo entre dois sucessivos cruzamentos por zero no sinal autocorrelacionado.

A média desses períodos é calculada por:

$$\bar{T}_p = 2 \frac{\sum_{i=1}^n \Delta t_i}{n} = \frac{2}{n} \sum_{i=1}^n (t_i - t_{i-1}), \quad (8)$$

onde Δt_i representa os intervalos adjacentes em que o sinal correlacionado cruza o zero.

2.7 Índice de regularidade

O teste de regularidade é aplicado com o objetivo de avaliar a existência de um comportamento não aleatório no sinal. O índice de regularidade r é utilizado para quantificar a regularidade dos períodos T_p detectados. Uma oscilação regular com um período bem definido apresenta $r > 1$.

O índice de regularidade de uma oscilação pode ser definido como (Thornhill et al., 2003):

$$r = \frac{1}{3} \frac{\overline{T_p}}{\sigma_{T_p}}, \quad (9)$$

onde $\overline{T_p}$ é a média dos períodos e σ_{T_p} é o desvio padrão dos períodos.

2.8 Agrupamento de frequências

Thornhill et al. (2003) apresentaram um índice utilizado para o agrupamento de frequências ligeiramente diferentes, expresso por:

$$d_{1,2} = \frac{|\overline{T_{p1}} - \overline{T_{p2}}|}{\max(\sigma_1 - \sigma_2)}, \quad (10)$$

onde $\overline{T_{p1}}$ e $\overline{T_{p2}}$ representam os períodos médios de dois sinais, e σ_1 e σ_2 são seus desvios padrões.

Dois períodos podem ser agrupados se $d_{1,2} < 1$. Nesse caso, os valores de $\overline{T_{p1}}$ e σ_1 serão mantido se $r_1 \geq r_2$. Caso contrário, faz-se $\overline{T_{p1}} = \overline{T_{p21}}$ e $\sigma_1 = \sigma_2$.

O agrupamento das frequências pode ser controlado por meio da multiplicação dos desvios padrões pelo valor escalar K_σ . Quanto maior o valor K_σ , mais frequências próximas serão agrupadas.

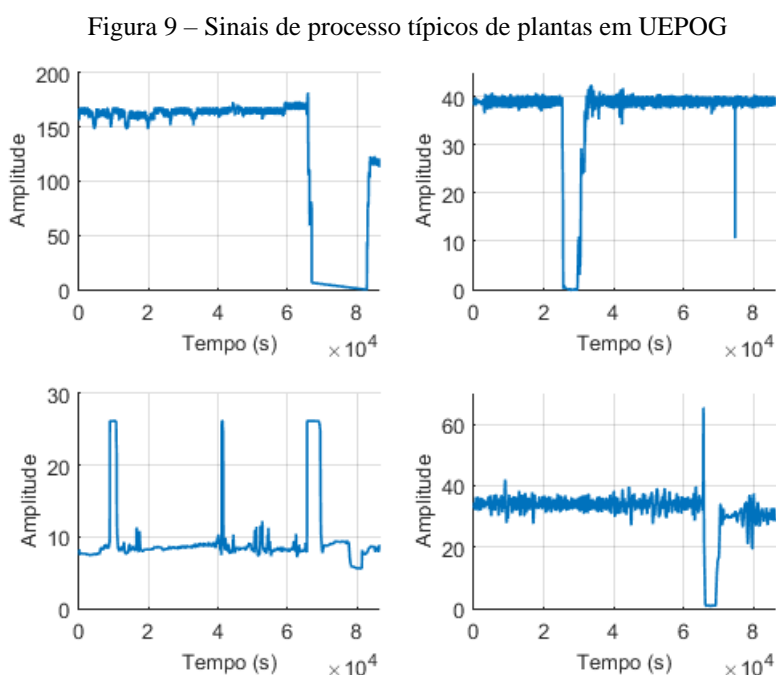
3 SEGMENTAÇÃO DE DADOS E AGRUPAMENTO DE OSCILAÇÕES DE MAIOR ENERGIA

Os resultados do método de detecção de oscilação podem ser comprometidos quando filtros inadequados são utilizados no pré-tratamento dos dados. A filtragem dos sinais pode provocar perda de informação ou até mesmo adicionar componentes oscilatórias indesejáveis. A interpretação da PSD também é dificultada quando o pré-tratamento não é realizado de forma correta, pois ruídos e distúrbios podem mascarar as frequências dominantes das oscilações.

Este capítulo apresenta uma metodologia de pré-tratamento para sinais provenientes de processos fortemente afetados por ruídos e distúrbios, bem como índices que quantificam o impacto das oscilações em função de sua variabilidade, conforme apresentado por Munaro et al. (2016, submetido).

3.1 Pré-tratamento dos dados

A Figura 9 exibe algumas variáveis de processo coletadas em malhas de controle de uma Unidade Estacionária de Produção de Óleo e Gás. Nota-se que os sinais apresentam *outliers* e/ou distúrbios acentuados. Essas componentes indesejáveis são bastante usuais em dados provenientes de plantas em UEPOGs.

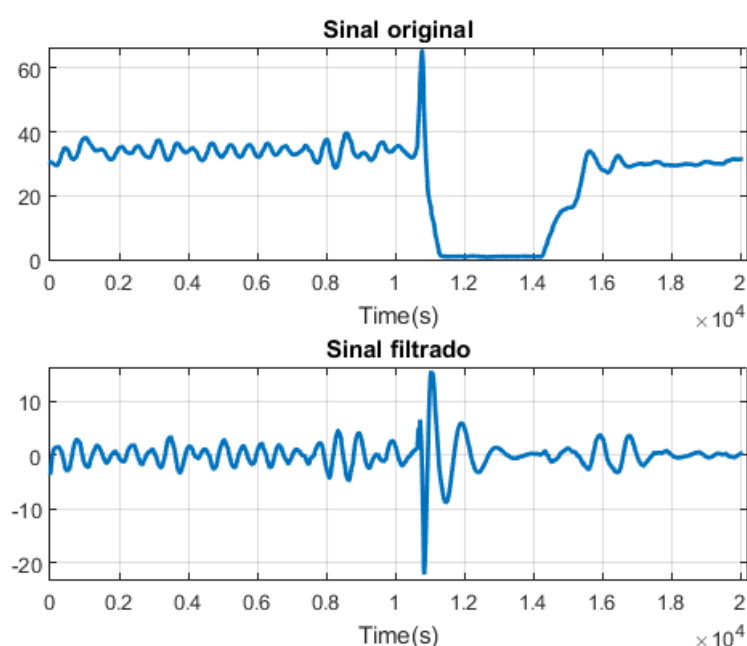


3.1.1 Filtro de pré-tratamento

Um filtro passa-banda é utilizado no método ODC. Karra e Karim (2009) sugerem o uso de bordas com valor normalizado de $[0,02 \ 0,99]$ Hz/Hz. O limiar inferior tem o objetivo de eliminar as componentes não estacionárias de baixa frequência, como tendências e/ou comportamentos transitórios. Já a escolha do limiar superior é justificada pela existência de frequências oscilatórias próximas da frequência de amostragem (1Hz/Hz), ocasionadas por ruídos de alta frequência.

Quando o filtro de pré-tratamento é aplicado a um sinal que possui *outliers* e/ou distúrbios muito acentuados, falsas frequências de oscilação são introduzidas após a filtragem, conforme pode ser observado na Figura 10. Isso ocorre, uma vez que a borda de baixa frequência do filtro produz polos muito próximos do círculo unitário. Sendo assim, o distúrbio, que possui efeito semelhante ao de um impulso, gera uma resposta oscilatória.

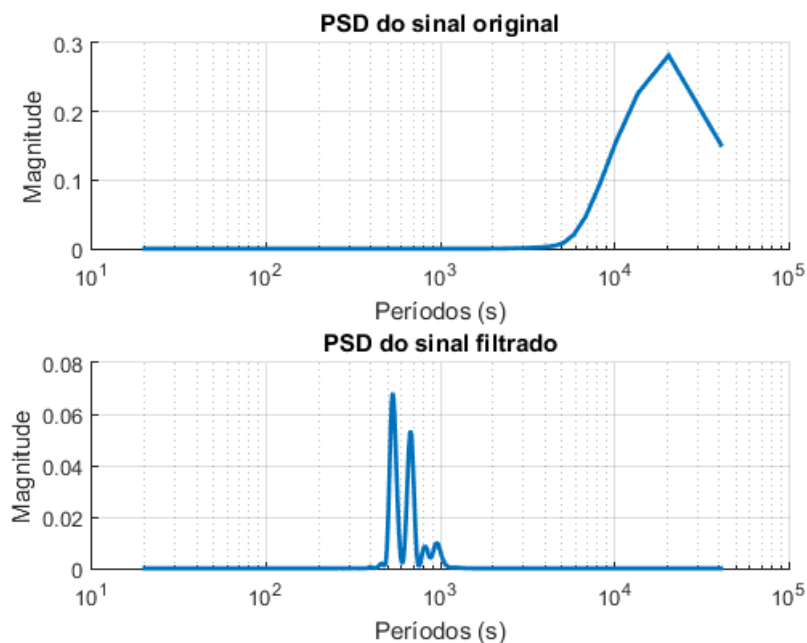
Figura 10 – Componentes oscilatórias introduzidas após a filtragem



Por outro lado, a ausência de um pré-tratamento dos dados faz com que o espectro de potência apresente atividade relevante apenas nas frequências associadas aos distúrbios. Isso ocasiona a não identificação das oscilações dominantes e compromete os resultados do método de detecção de oscilação.

A Figura 11 exibe o espectro de potência do sinal ilustrado na Figura 10. São mostradas as PSDs do sinal original e do sinal filtrado, sendo possível visualizar que o não tratamento dos dados impede a identificação das bandas de frequência associadas às oscilações.

Figura 11 – PSD do sinal original e PSD do sinal filtrado



Com o objetivo de evitar as falsas componentes oscilatórias introduzidas pelo filtro, propõe-se uma metodologia para o pré-tratamento do sinal. A próxima seção apresenta o algoritmo utilizado para selecionar apenas os segmentos de dados livres de variações abruptas.

3.1.2 Seleção de segmentos de dados

A seleção de segmentos é feita por meio da distribuição de frequência dos dados (histograma). Suponha um sinal x_t de um processo no qual se deseja detectar oscilações. O passo a passo descrito abaixo informa sobre a metodologia utilizada para o pré-tratamento desse sinal. Os parâmetros n_b , $limiar$, n_{std} e n_d correspondem aos parâmetros de entrada do algoritmo.

- 1) Calcular o histograma de x_t , utilizando n_b classes (bins);
- 2) Selecionar a classe L com o maior número de elementos (e_L);
- 3) Buscar as classes adjacentes a L . Se o número de elementos da classe analisada é superior a $(e_L * limiar)$, a classe será selecionada. Repete-se essa etapa até encontrar a primeira classe superior a L em que o número de elementos é inferior a $e_L * limiar$, e a primeira classe inferior a L em que o número de elementos é inferior a $e_L * limiar$;

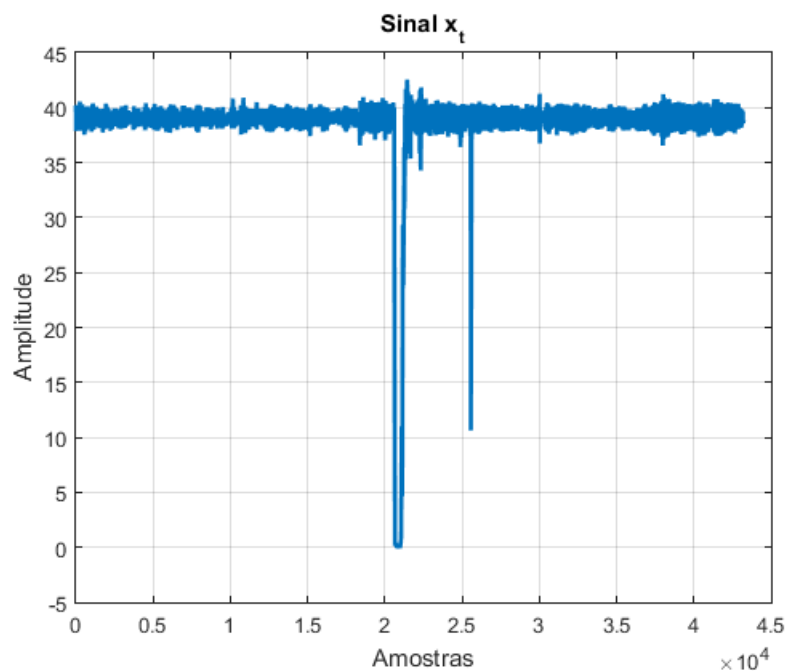
- 4) Definir os valores mínimo e máximo entre todas as classes selecionadas e encontrar os valores de x_t que estão dentro desse intervalo. O resultado será um sinal x_{tt} ;
- 5) Também serão incluídos os dados que possuem valor inferior a $\mu(x_{tt}) \pm n_{std} \times \sigma(x_{tt})$, onde $\mu(x_{tt})$ corresponde à média de x_{tt} e $\sigma(x_{tt})$ corresponde ao desvio padrão desse sinal;
- 6) Por fim, escolhe-se o maior segmento de dados consecutivos. Há uma tolerância de n_d amostras entre dois segmentos descontínuos. Caso o número de descontinuidades entre os segmentos seja inferior a n_d , os dois segmentos são concatenados. Caso esse número de descontinuidades seja superior a n_d , os segmentos não são unidos e o maior deles é selecionado.

As próximas seções apresentam as etapas do passo a passo de forma mais detalhada. Também serão discutidos os efeitos causados por variações nos parâmetros de entrada.

3.1.2.1 Cálculo do histograma

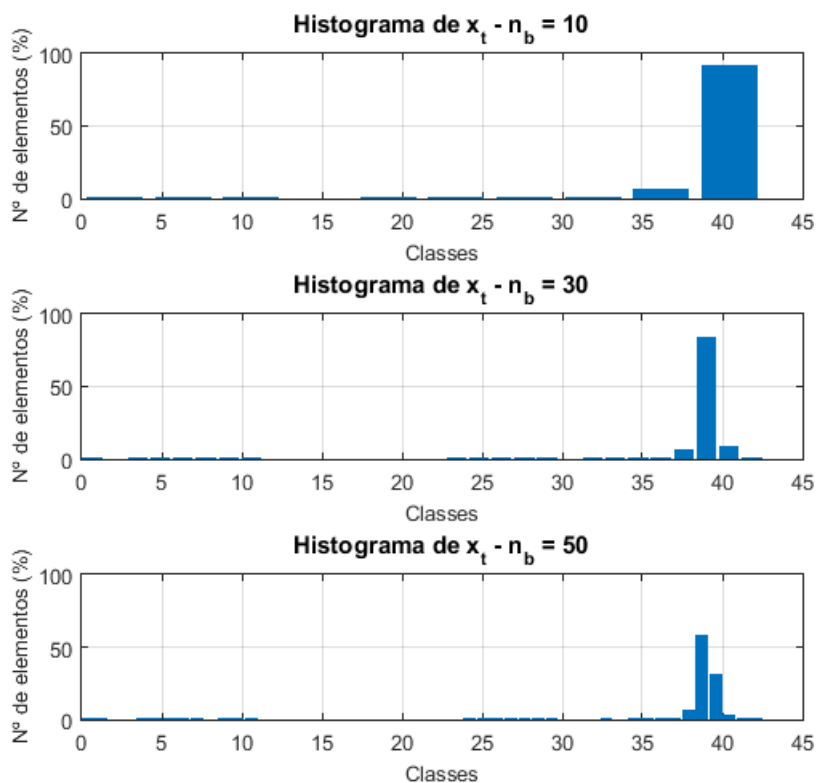
A Figura 12 exibe um sinal de processo coletado de uma malha de controle, ao qual o algoritmo de pré-tratamento será aplicado.

Figura 12 – Sinal exemplo para a explicação das etapas do passo a passo



A primeira etapa do método proposto consiste no cálculo da distribuição de frequência do sinal. A Figura 13 demonstra os histogramas produzidos utilizando $n_b = 10$, $n_b = 30$ e $n_b = 50$. A variação do parâmetro n_b será discutida nas seções 5.1.2.2 e 5.1.2.3.

Figura 13 – Histogramas de x_t utilizando $n_b = 10$, $n_b = 30$ e $n_b = 50$



3.1.2.2 Seleção da classe de maior número de elementos

A segunda etapa consiste em selecionar a classe L com o maior número de elementos. Quanto menor for o valor de n_b , mais elementos estarão contidos em L . Não é interessante atribuir valores muito baixos a esse parâmetro ($n_b < 10$), pois os dados retidos poderão possuir elevada dispersão e apresentar variações abruptas.

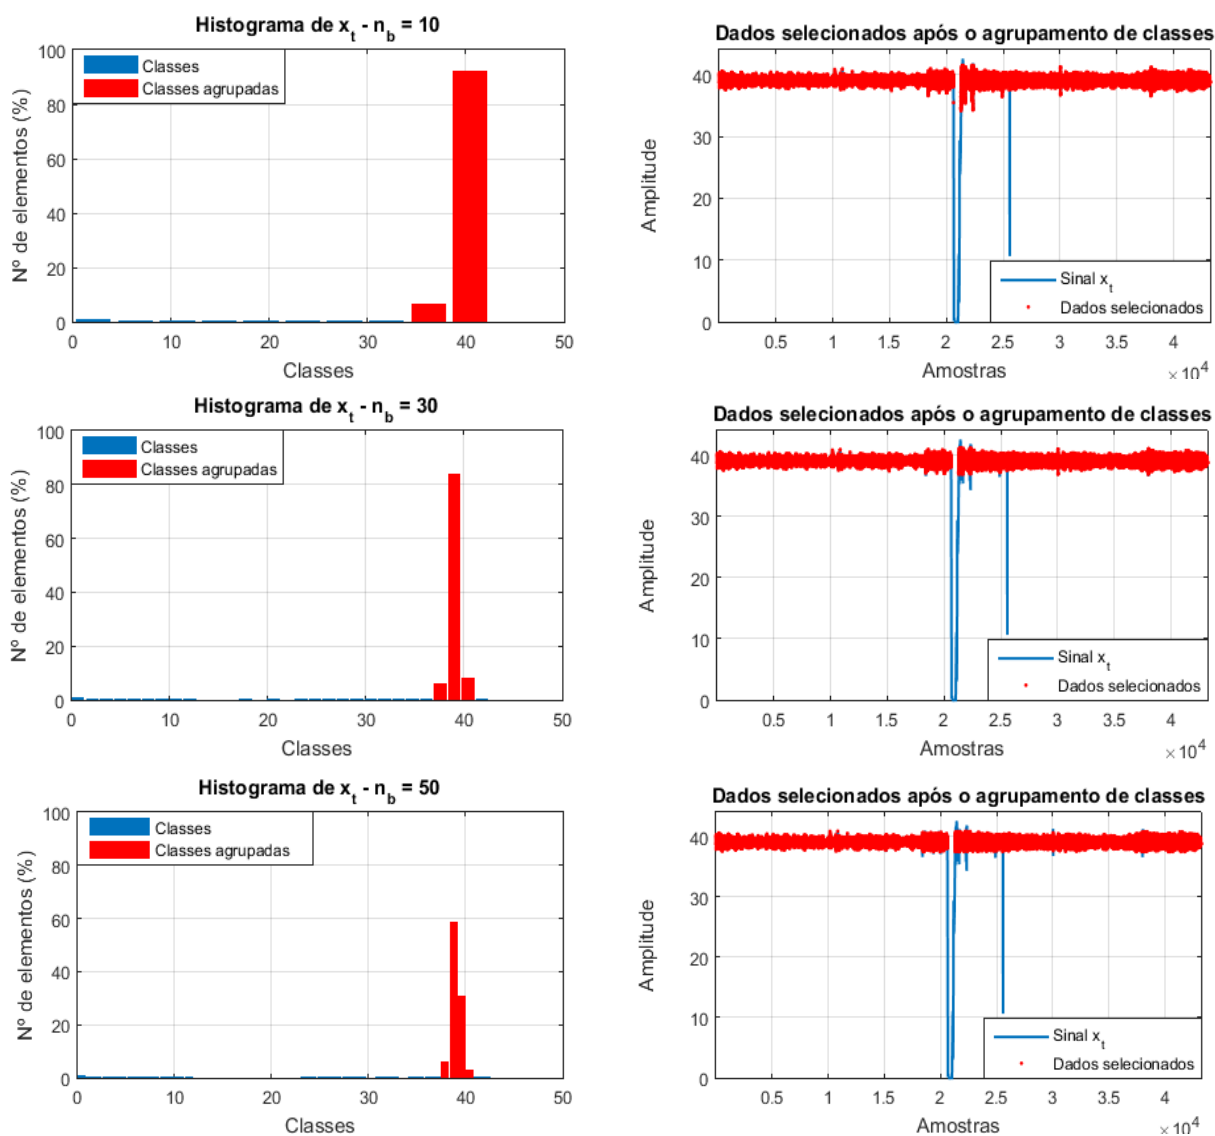
3.1.2.3 Agrupamento de classes adjacentes

O parâmetro *limiar* pode assumir valores no intervalo $[0,1]$. Nessa etapa, é importante que o usuário compreenda o efeito desse índice: quanto maior for o valor de *limiar*, mais restritiva será a seleção de dados. Isso significa que o algoritmo tenderá a descartar mais amostras, no entanto, os dados selecionados apresentarão menor dispersão. Analogamente, valores muito

baixos de limiar provocam o descarte de menos amostras, contudo os dados selecionados possuirão maior desvio padrão.

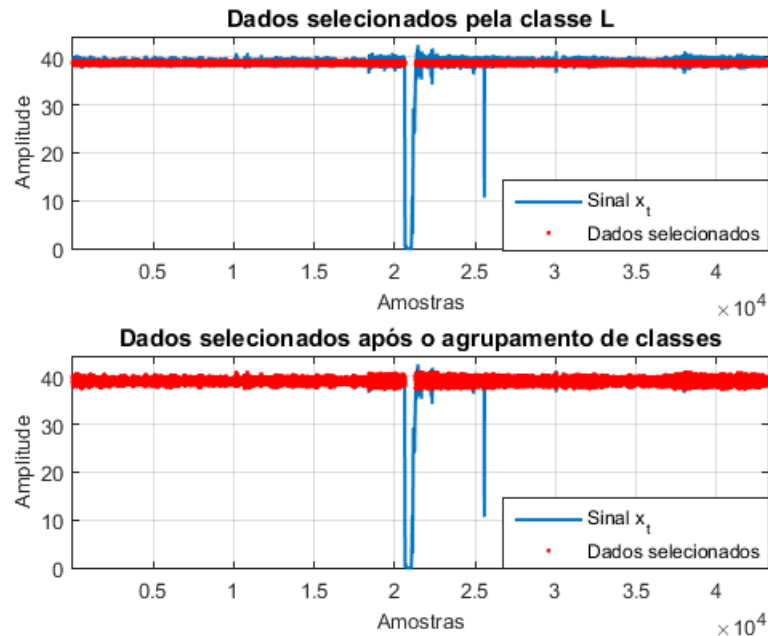
A Figura 14 exibe os resultados obtidos após o agrupamento de classes adjacentes considerando valores de n_b iguais a 10, 30 e 50. O parâmetro *limiar* foi mantido fixo em 2,5%. O uso de 10, 30 e 50 classes promoveu a retenção de 98,4%, 98% e 97,7% dos dados, respectivamente. Dessa forma, é possível concluir que a redução de n_b proporciona a retenção de mais dados, porém a informação selecionada possui maior variabilidade.

Figura 14 – Classes agrupadas atribuindo *limiar* = 2,5 %. Utilizou-se $n_b = 10$, $n_b = 30$ e $n_b = 50$



Para preservar a regularidade do segmento, será adotado $n_b = 50$. A Figura 15 exibe o sinal x_t e as amostras selecionadas nas etapas 3 e 4.

Figura 15 – Amostras selecionadas nas etapas 3 (cima) e 4 (baixo) do algoritmo. Utilizou-se $limiar = 2,5$ e $n_b = 50$

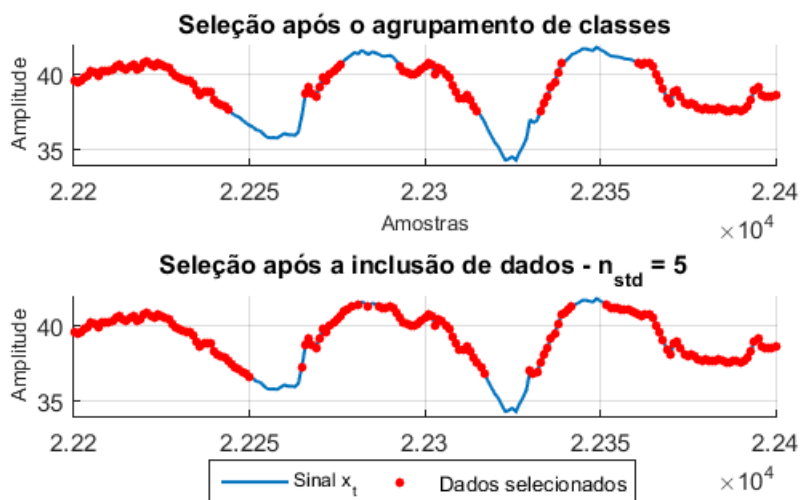


3.1.2.4 Inclusão de elementos com valor superior a $\mu(x_{tt}) \pm n_{std} \times \sigma(x_{tt})$

Possui a finalidade de incluir mais amostras aos dados previamente selecionados. Essa etapa é importante, pois reduz as discontinuidades entre os segmentos selecionados, permitindo que o algoritmo retorne um fragmento de maior tamanho. Quanto maior for o parâmetro n_{std} maior será a inclusão de dados.

A Figura 16 ilustra o resultado do método de pré-tratamento após a inclusão descrita nesta seção. Utilizou-se $n_{std} = 5$. Como o sinal x_{tt} obtido na etapa anterior possui pequeno desvio padrão ($\sigma(x_{tt}) = 0,48$), os resultados encontrados entre as etapas 4 e 5 não são muito contrastantes.

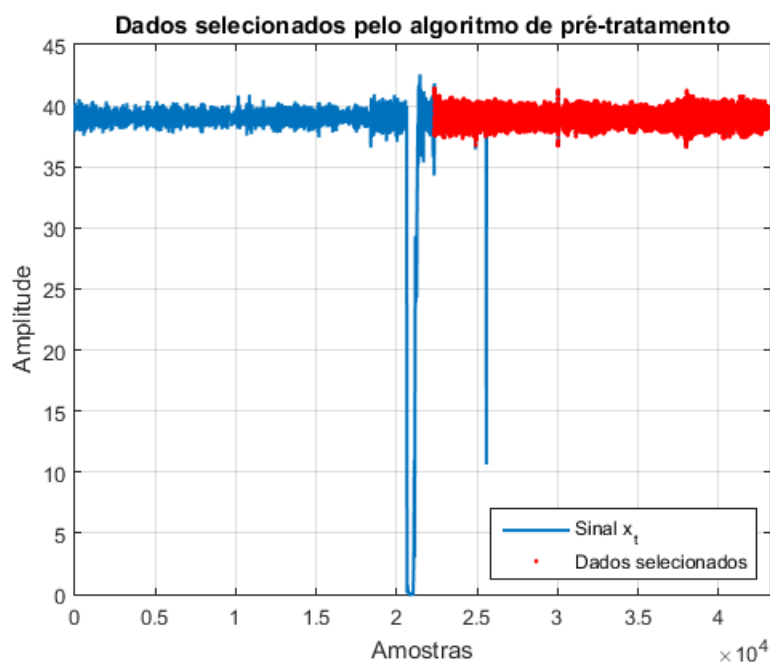
Figura 16 - Amostras selecionadas nas etapas 4 (cima) e 5 (baixo) do algoritmo. Utilizou-se $n_{std} = 5$



3.1.2.5 Eliminação de trechos com descontinuidades

A Figura 17 exibe o resultado final fornecido pelo algoritmo. Utilizou-se $n_d = 3$, $n_{std} = 5$, $limiar = 2,5\%$ e $n_b = 50$. Nota-se que houve a concatenação de dois segmentados de dados, separados por um *outlier*. Como a descontinuidade entre os segmentos foi menor do que n_d amostras, o outlier foi descartado e os grupos de dados foram unidos.

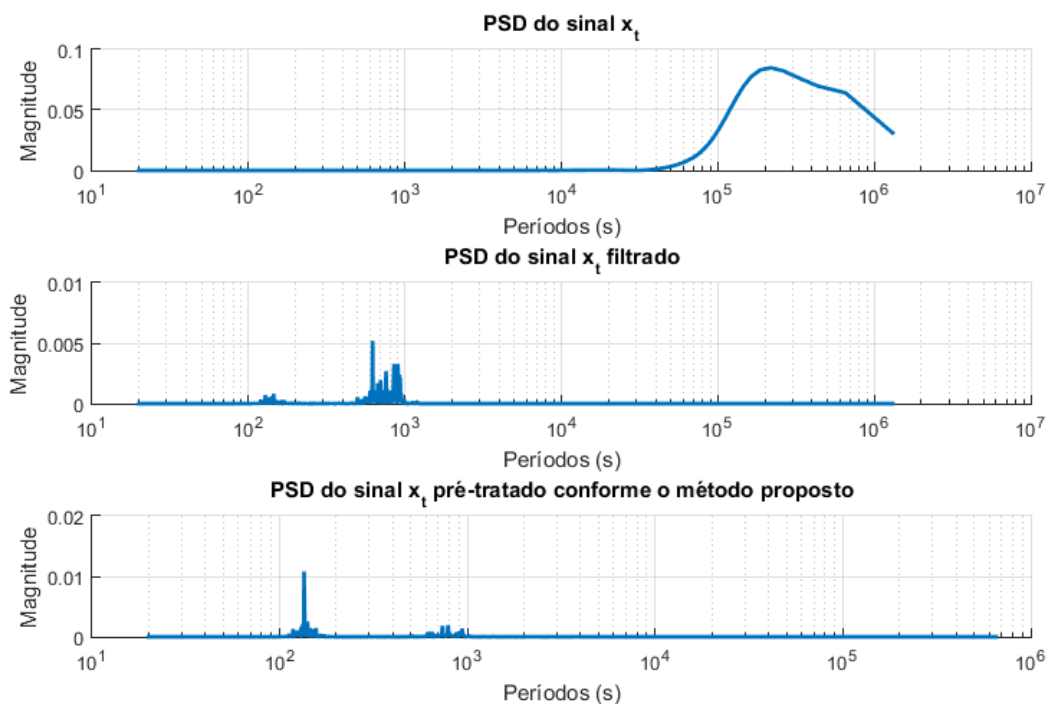
Figura 17 – Resultado final fornecido pelo algoritmo de pré-tratamento. Utilizou-se $n_d = 3$



3.1.2.6 Resultados da rotina de pré-tratamento

A Figura 18 exibe as PSDs do sinal original, do sinal filtrado e do sinal pré-tratado.

Figura 18 – PSDs do sinal original, do sinal filtrado e do sinal pré-tratado



É possível visualizar que o método de pré-tratamento cumpriu o seu propósito, pois foram eliminados os distúrbios de baixa frequência (período elevado), sem a necessidade de filtragem e a possível adição de componentes oscilatórias.

3.2 Quantificação do impacto das oscilações

A quantificação do impacto de uma oscilação não deve se basear exclusivamente na energia obtida por meio da PSD. Essa afirmação pode ser justificada a partir do seguinte fato: sinais que possuem apenas uma oscilação apresentarão energia elevada no espectro de potência, mesmo que a amplitude dessa oscilação não seja significativa. Isso ocorre, pois a densidade espectral de potência é normalizada conforme a equação 3. Com o objetivo de evitar a situação descrita, sugere-se o uso do Coeficiente de Variação.

O Coeficiente de Variação de Pearson mede a variabilidade do sinal em relação a sua média, sendo dado por:

$$CV = \frac{\sigma(x_t)}{\mu(x_t)} * 100, \quad (11)$$

onde $\mu(x_t)$ corresponde à média do sinal x_t e $\sigma(x_t)$ corresponde ao seu desvio padrão.

Esse índice possui a vantagem de quantificar a amplitude das oscilações no domínio do tempo, uma vez que sinais oscilatórios com amplitudes elevadas apresentam maior $\sigma(x_t)$. No entanto, assim como a energia, o CV não deve ser utilizado unicamente. Caso o método ODC identifique a presença de várias frequências dominantes em um mesmo sinal, o uso exclusivo do Coeficiente de Variação geraria índices iguais para todas as oscilações, pois ele está associado ao sinal no tempo. Nesse caso, as energias das oscilações não seriam levadas em consideração, o que não é interessante. A solução desse impasse foi a utilização do CV do sinal pré-tratado multiplicado pela energia da oscilação. Esse novo índice, denominado de CVE, será utilizado neste trabalho para avaliar o impacto das oscilações.

A Figura 19 exibe um sinal no tempo coletado de uma malha de controle e sua respectiva PSD normalizada. Como não existem *outliers* e distúrbios acentuados, o algoritmo de pré-tratamento selecionou todas as amostras. A energia de cada oscilação é exibida no gráfico da PSD, ao lado dos picos selecionado pelo método ODC.

O CV do sinal apresentado na Figura 19 é 0,017. Caso o CV não fosse ponderado pela energia, ambas as oscilações seriam diagnosticadas com o mesmo impacto. Com a utilização do CVE, foram encontrados os seguintes resultados:


- Oscilação de maior energia

$$CVE = 0,017 * 70,02\% = 0,0119$$

- Oscilação de menor energia

$$CVE = 0,017 * 10,46\% = 0,0018$$

Figura 19 – Sinal no tempo e sua PSD normalizada.



Dessa forma, a oscilação de maior energia é identificada corretamente como a mais impactante. No entanto, como o sinal possui baixo desvio padrão e pouca variabilidade, ambas as oscilações não possuem um CVE tão relevante. A utilização do CV impede que oscilações de baixa amplitude sejam comparáveis às oscilações de amplitude mais elevada.

3.3 Agrupamento de oscilações presentes em diferentes sinais

A seção 2.9 descreve a metodologia utilizada para agrupar oscilações contidas em um mesmo sinal. Por outro lado, a metodologia de agrupamento proposta nesta seção deve ser aplicada ao conjunto de oscilações identificadas em todos os sinais de processo.

O agrupamento das oscilações se torna necessário, uma vez que as mesmas se propagam por malhas próximas e podem ser detectadas com frequências ligeiramente diferentes. É importante ressaltar que devem ser associadas apenas as oscilações de períodos semelhantes,

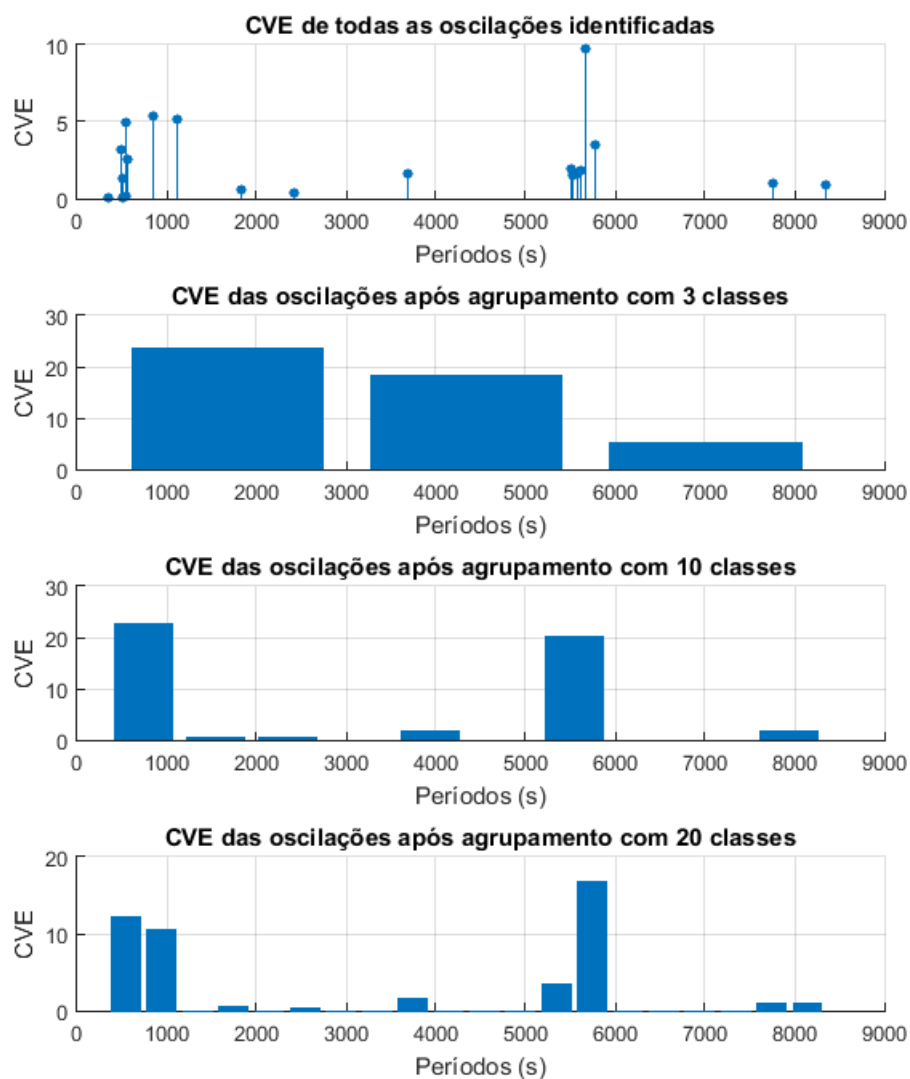
caso contrário, oscilações oriundas de diferentes problemas no sistema de controle poderão ser agrupadas. Isso poderia impossibilitar o diagnóstico de um problema severo que estaria comprometendo o desempenho da produção.

Este trabalho propõe que o agrupamento seja feito por meio do histograma. Nesse contexto, o número de classes deve ser escolhido com cautela. O uso de poucas classes pode fazer com que períodos muito distantes sejam agrupados. Por outro lado, a utilização de um número muito elevado pode não atender ao propósito do agrupamento e não associar as oscilações que possuem a mesma causa raiz.

Durante o agrupamento, os CVE das oscilações que pertencem a uma mesma classe serão somados. Cada grupo corresponderá então a uma única oscilação que se propagou para uma ou mais malhas de controle. Dessa forma, vale destacar que o CVE de um grupo não está relacionado somente à amplitude e à energia de sua oscilação, mas também ao número de sinais afetados por ela. Um valor de CVE elevado pode ocorrer devido a uma oscilação que afeta poucos sinais de maneira intensa (com elevada amplitude de oscilação) ou devido a uma oscilação que afeta muitos sinais de maneira mediana ou reduzida. O período de oscilação dos grupos será representado pelos centros das classes.

A Figura 20 mostra o resultado do método de agrupamento descrito nesta seção. O algoritmo de detecção de oscilações foi aplicado a dados reais, coletados do sistema de processamento de óleo de uma UEPOG. O primeiro gráfico (de cima para baixo) exibe todas as oscilações identificadas em um intervalo de 24 horas. Nesse contexto, foram gerados grupos, por meio de histogramas, com 3 classes, 10 classes e 20 classes. O uso de 3 classes não se mostrou adequado (segundo gráfico de cima para baixo), uma vez o agrupamento uniu informações de períodos muito distantes. Já o agrupamento obtido com 10 e 20 classes (terceiro e quarto gráfico) foi mais fiel aos grupos visualmente perceptíveis no primeiro gráfico.

Figura 20 – Agrupamento das oscilações utilizando histogramas com 3 classes (incorreto), 10 classes e 20 classes



4 IMPLEMENTAÇÃO EM AMBIENTE INDUSTRIAL

Este capítulo descreve como os algoritmos apresentados nas seções 2 e 3 são utilizados para o monitoramento remoto de ativos de um processo industrial.

Esses algoritmos foram transformados em um bloco de execução dentro de uma plataforma, denominada PGA, dedicada à supervisão de plantas industriais.

O desenvolvimento e a programação de blocos compatíveis com a plataforma também são temas abordados neste capítulo.

4.1 PGA

A Plataforma de Gestão de Ativos (PGA) foi desenvolvida pela empresa TriSolutions com o objetivo de viabilizar o monitoramento da eficiência dos ativos de um processo. Dessa forma, a plataforma também permite a localização e o diagnóstico de problemas, proporcionando apoio à resolução dos mesmos.

Devido à forma como a PGA é estruturada, seus usuários não necessitam possuir conhecimentos especializados para a execução de análises que visam o monitoramento dos ativos. As análises são programadas por meio de blocos interligados entre si. Sendo assim, basta que o usuário conheça o propósito de cada bloco, não necessitando entender profundamente sobre o seu funcionamento.

As próximas seções explicam alguns conceitos e ferramentas disponíveis na plataforma, necessários para o seu entendimento.

4.1.1 Ativo de Processo


Qualquer entidade vinculada aos dados de processo, como por exemplo: fornos, motores, trocadores de calor, entre outros.

4.1.2 Plug-in

É um bloco intermediário que realiza o processamento dos dados. Utilizando conceitos de programação, Plug-ins são definidos como subrotinas armazenadas em bibliotecas dinâmicas

(Dynamic Link Library - DLL), que são chamadas pela PGA, quando necessário. Os dados de entrada são selecionados pelo próprio usuário e os resultados estão disponíveis por meio das saídas. A Figura 21 exibe as etapas envolvidas no funcionamento do Plug-in.

Figura 21 – Etapas envolvidas no funcionamento do Plug-in



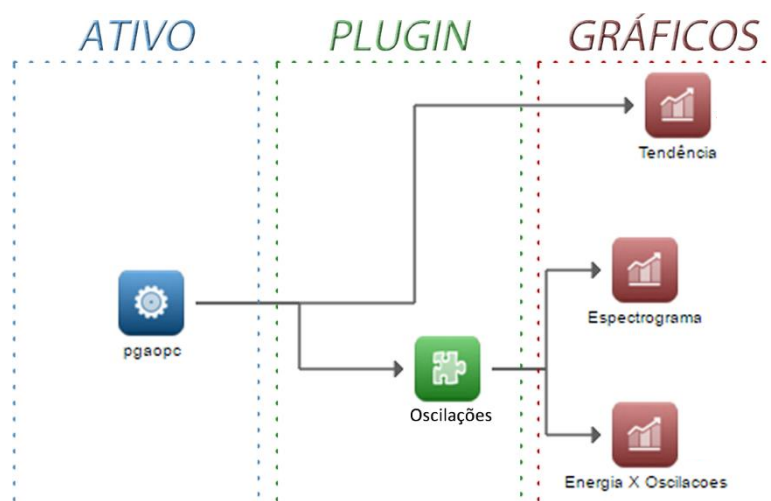
Este trabalho propõe o desenvolvimento de um Plug-in a partir dos algoritmos descritos nos capítulos 2 e 3.

4.1.3 Análise

Viabiliza o monitoramento de um ou mais ativos e é constituída por blocos interligados entre si. Esses blocos são organizados em Ativos, Plug-ins e Gráficos.

Os ativos de processo estão disponíveis ao usuário por meio dos blocos de Ativos. Caso seja necessário processar esses dados, o bloco deve ser conectado a um Plug-in, escolhido conforme a necessidade do usuário. Os dados processados podem ser visualizados através dos blocos gráficos. A Figura 22 exemplifica uma análise.

Figura 22 – Exemplo ilustrativo de uma análise.



Para a execução de análises na plataforma PGA, é necessário que o usuário escolha uma data específica para a coleta dos ativos no banco de dados.

4.1.4 Visualizador de Resultados

Ferramenta que permite a visualização de todos os gráficos gerados por uma análise. A PGA possui blocos gráficos de diversos tipos (tendência, logaritmo, histograma, XY, etc), sendo possível que o usuário da plataforma escolha o bloco que melhor atenda ao propósito de sua análise.

No exemplo ilustrado na Figura 22, o usuário deverá acessar o Visualizador de Resultados para consultar os gráficos produzidos após a execução da análise. Nesse caso, será exibido o gráfico de tendência do ativo de processo “pgaopc”, um espectrograma e um gráfico do tipo XY de Energia *versus* Oscilações.

É importante destacar que essa ferramenta produz gráficos referentes a uma única análise, apenas. A comparação entre resultados obtidos em análises distintas é feita por meio de uma ferramenta denominada Relatório Gerencial.

4.1.5 Relatório Gerencial

Permite que o usuário acompanhe os resultados produzidos pelo(s) Plug-in(s) após a execução de análises distintas. Contudo, só estão disponíveis no Relatório Gerencial as variáveis escalares geradas ao longo do período de execução das análises. Qualquer outra saída vetorial ou matricial não poderá ser visualizada nessa ferramenta.

O acompanhamento dos resultados é feito por meio de um gráfico, cujo eixo das abscissas corresponde à data da análise e o eixo das ordenadas corresponde ao valor da variável escalar. Cada escalar produzida possui um gráfico correspondente. Dessa forma, supondo uma análise que retorne três variáveis escalares, serão gerados três gráficos distintos no Relatório Gerencial, não sendo possível a visualização de mais de uma curva em um único gráfico.

Essa ferramenta é importante no contexto deste trabalho, uma vez que as oscilações que demandam medidas corretivas são aquelas que afetam o processo durante várias análises

subsequentes. Sendo assim, é necessário que o usuário realize o acompanhamento dos resultados no Relatório Gerencial para identificar quais oscilações merecem ser investigadas.

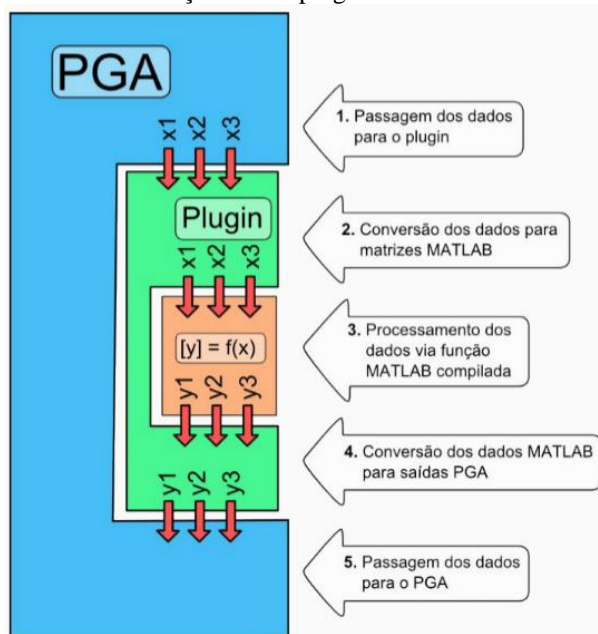
4.2 Desenvolvimento dos Plug-ins

A elaboração de Plug-ins é feita por meio de uma interface de programação (API) escrita em linguagem C++. Embora C++ seja flexível e eficiente, o uso de uma linguagem científica é mais indicado para o desenvolvimento do Plug-in proposto, uma vez que essa suporta nativamente diversas operações matriciais e funções de cálculo numérico, proporcionando aos programadores velocidade no desenvolvimento de seus códigos. Portanto, os algoritmos descritos nos capítulos 2 e 3 deste trabalho foram desenvolvidos em linguagem MATLAB.

Dessa forma, propôs-se o mapeamento de uma função MATLAB para um Plug-in PGA. Isso é possível, desde que os tipos de dados manipulados pelo PGA sejam devidamente mapeados por um *middleware* para tipos de dados MATLAB (vetores e matrizes). Além disso, é necessário que a função MATLAB seja compilada para C++, por meio do MATLAB Compiler.

Utilizou-se uma interface (Template no Visual Studio) para a programação do *middleware*. Com esta interface desenvolvida, o programador da função MATLAB precisa apenas escrever um breve código em C++, listando os tipos dos dados de entrada, os tipos dos dados de saída e alguns atributos intrínsecos ao plug-in (nome, versão, autor, etc). O diagrama da Figura 23 exhibe o fluxo de dados durante a execução de um Plug-in no PGA.

Figura 23 - Fluxo de dados durante a execução de um plug-in PGA utilizando uma rotina MATLAB



4.3 Plug-in de detecção de oscilação

Os algoritmos de seleção de segmentos e detecção de oscilação foram transformados em um único Plug-in, cuja finalidade é detectar ativos que possuem comportamento oscilatório. As próximas seções informam detalhes do bloco criado.

4.3.1 Entradas

Estão listadas abaixo as entradas do Plug-in proposto. Esses parâmetros foram explicados detalhadamente ao longo dos capítulos 2 e 3.

- **Sinais de processo:** Sinais de processo que serão avaliados com o objetivo de verificar a existência de oscilações. Obrigatoriamente, os sinais 1 e 2 devem ser passados como parâmetros de entrada. São suportados até 36 sinais;
- T_s : Tempo de amostragem;
- α : Fator de alisamento da PSD;
- K_σ : Número de desvios padrão considerados no agrupamento das oscilações presentes em um sinal;
- ϵ_e : Limiar de energia;
- n_b : Número de classes utilizadas pela rotina de seleção de segmentos de dados;
- **limiar:** Limiar que será considerado para o agrupamento de classes adjacentes;
- n_{std} : Número de desvios padrão considerados para a inclusão de mais dados;

- n_d : Número de descontinuidades consideradas para a concatenação de segmentos distintos.

4.3.2 Saídas

Para facilitar a interpretação do usuário e reduzir a quantidade de informações, serão consideradas somente as oscilações de maior impacto (os três maiores CVE) após o agrupamento de frequências com o uso de histogramas. Tal consideração é justificável, uma vez que é pouco comum a existência de mais de três oscilações simultâneas com frequências distintas (Thornhill et al., 2003). Dessa forma, o Plug-in identificará, no máximo, três períodos distintos de oscilação.

O Visualizador de Resultados informará ao usuário quais foram os sinais de processo que apresentaram comportamentos oscilatórios, bem como a intensidade da oscilação presente nos mesmos. Já o Relatório Gerencial apresentará os períodos das oscilações detectadas, os CVE associados às mesmas e o percentual de retenção de dados do algoritmo de seleção de segmentos, calculados em diferentes análises.

As seções abaixo discutem de forma mais detalhada as saídas disponíveis para as ferramentas Visualizador de Resultados e Relatório Gerencial.


4.3.2.1 Visualizador de Resultados

Foi especificado para a empresa TriSolutions o desenvolvimento de um gráfico matricial que exhibe os sinais de processo *versus* períodos das oscilações detectadas. Naturalmente, esse gráfico é gerado por meio de uma saída matricial, cujas linhas representam os sinais de processo e as colunas correspondem às oscilações identificadas pelo Plug-in.

O propósito do gráfico citado é informar a contribuição (CVE) de cada sinal para cada oscilação. Para tanto, ele funciona da seguinte forma: o CVE é representado pelo desenho de um círculo. Quanto maior for a contribuição de um sinal para uma oscilação específica, maior será o tamanho do círculo, que estará localizado na linha referente ao sinal e na coluna referente à oscilação. Sinais que apresentam CVE nulo não possuem desenho sobre sua identificação. As oscilações (colunas) são identificadas por meio de uma *string* que contém o seu período.

A Figura 24 exemplifica o funcionamento do gráfico matricial. Vale destacar que a implementação desse recurso na PGA instalada na Universidade Federal do Espírito Santo não foi concluída, portanto não houve tempo hábil para a apresentação do gráfico no capítulo que descreve os resultados deste trabalho.

Figura 24 – Exemplo do gráfico matricial



4.3.2.2 Relatório Gerencial

As saídas disponíveis ao usuário da PGA no Relatório Gerencial são:

- Três variáveis escalares com o período de cada oscilação. Essas são organizadas em ordem decrescente de período.
- Três variáveis escalares com os três maiores CVE calculados em uma análise.
- Escalar com o percentual de retenção de dados do algoritmo de seleção de segmentos (ver seção 3.1.2).

5 APLICAÇÃO AOS DADOS REAIS

Neste capítulo o Plug-in desenvolvido foi utilizado para avaliar o comportamento oscilatório de ativos de um processo industrial real.

A seção 5.1 apresenta os sinais utilizados neste estudo de caso, os quais são provenientes de uma planta industrial em uma UEPOG. A seção 5.2 exibe os sinais pré-tratados, conforme a metodologia apresentada no capítulo 3. Já a seção 5.3 valida os resultados obtidos por meio do algoritmo de detecção de oscilação. Por fim, a seção 5.4 exibe como os resultados são apresentados ao usuário do PGA e, além disso, orienta sobre a interpretação dos mesmos.

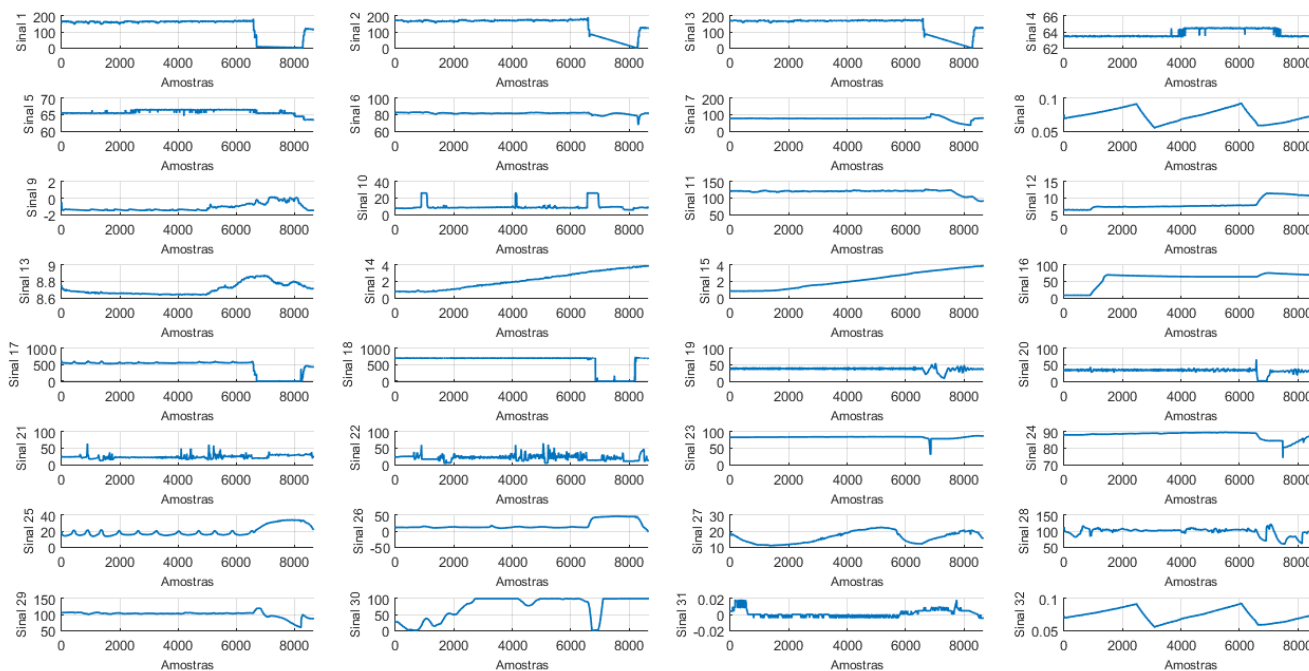
5.1 Dados provenientes de um processo industrial real

Os sinais analisados neste capítulo foram coletados do sistema de processamento de óleo de uma plataforma de produção e armazenamento de petróleo durante os dias 01/07/2016 17:00 a 05/07/2016 17:00. Os algoritmos de detecção de oscilação são executados após a conclusão de 24 horas de processo, sendo assim serão analisados quatro dias.

Os dados analisados são fornecidos por um sistema de gerenciamento de informações (PIMS) com tempo de amostragem de 10 s e interpolação linear entre as amostras. Portanto, cada análise diária é realizada com 8.640 amostras de um sinal.

A Figura 25 exibe os 32 sinais de processo coletados durante o primeiro dia. Esses sinais serão utilizados na próxima seção para demonstrar os resultados proporcionados pelo algoritmo de seleção de segmentos. Como é possível visualizar na figura, alguns sinais apresentam um comportamento oscilatório evidente, portanto é imprescindível que esses sinais sejam identificados pelo algoritmo de detecção de oscilação (por exemplo, sinal 17 e sinal 25).

Figura 25 – Variáveis de processo do sistema de processamento de óleo de uma UEPOG



5.2 Seleção de segmentos de dados

A Figura 26 exibe os dados selecionados (em vermelho) pelo algoritmo de seleção de segmentos durante as primeiras 24 horas analisadas. Assim como no caso exemplificado na seção 5.1.2, utilizou-se $n_d = 3$, $n_{std} = 5$, $limiar = 2,5\%$ e $n_b = 50$. Nota-se que nenhum segmento que contém variações abruptas foi incluído na seleção. Também é possível visualizar que todos os sinais que possuem tendência (por exemplo, sinal 15 e 16) foram completamente retidos. Esses sinais são tratados antes da execução do algoritmo de detecção de oscilação, uma vez que tendências podem produzir uma ACF com resultados inconclusivos (Chatfield, 2003, p.29). Portanto, essas componentes indesejáveis serão removidas dos sinais.

O percentual de dados retidos por sinal é exibido na Figura 27. A média dos dados selecionados neste dia foi de 71,5%. O usuário deve ficar atento a esse índice, pois muitos descartes podem provocar variações no resultado do método de detecção de oscilação. Isso ocorre, pois quanto menor for o tamanho do segmento selecionado, menores serão os períodos das oscilações identificadas, já que são necessários, no mínimo, 8 cruzamento por zero (4 períodos) para que uma oscilação seja considerada regular. Por exemplo, no caso do sinal 5 em que 14,5% dos dados foram retidos, o período de oscilação máximo que poderá ser identificado é de, aproximadamente, 3.132 s.

Figura 26 – Dados retidos pelo algoritmo de seleção de segmentos (em vermelho)

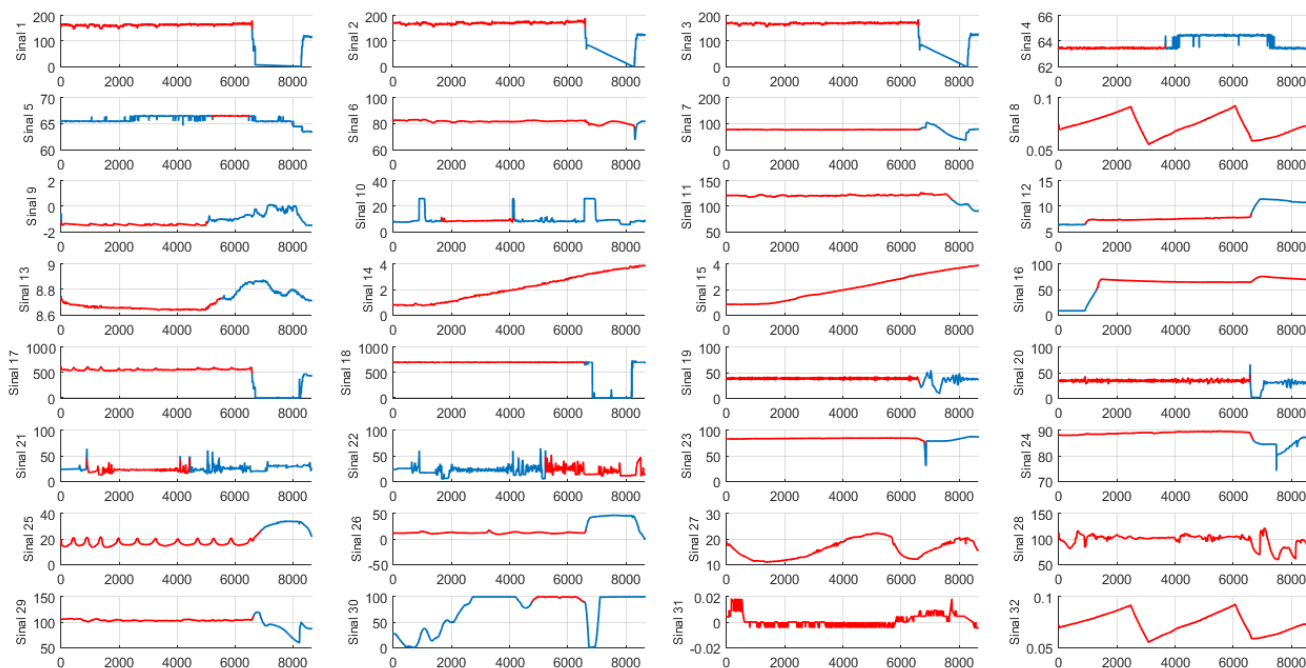

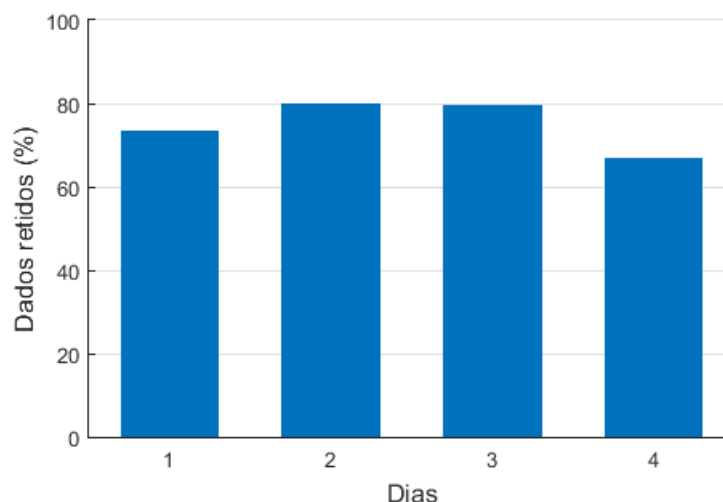


Figura 27 – Percentual de retenção por sinal



A Figura 28 exibe a média de dados selecionados para os quatro dias de análise. Em média, mais de 65% dos dados foram retidos em todos os dias. Uma vez que os distúrbios não oscilatórios foram removidos pela rotina de seleção de segmentos, a utilização de filtros não é mais necessária.

Figura 28 – Percentual médio de dados retidos por dia




5.3 Validação do algoritmo de detecção de oscilações

O algoritmo de detecção de oscilação discutido no Capítulo 2 foi aplicado aos dados pré-tratados. Um total de 79 oscilações distintas foram detectadas nos 32 sinais durante os quatro dias analisados. A Figura 29 exibe o CVE de todas as oscilações identificadas durante esse intervalo de tempo. Não foi utilizado o agrupamento descrito na seção 3.3.

Fica claro, por meio da Figura 29, que as informações mais relevantes devem ser extraídas da grande quantidade de saídas. O agrupamento descrito na seção 3.3, por si só, já é capaz de sintetizar os resultados, uma vez que períodos próximos são congregados em um único grupo. Além disso, somente os grupos com os três maiores CVE foram considerados para a exibição dos resultados diários, conforme explicado na seção 4.3.2. Dentre esses grupos, aqueles que possuíam CVE inferior a 2% foram negligenciados.

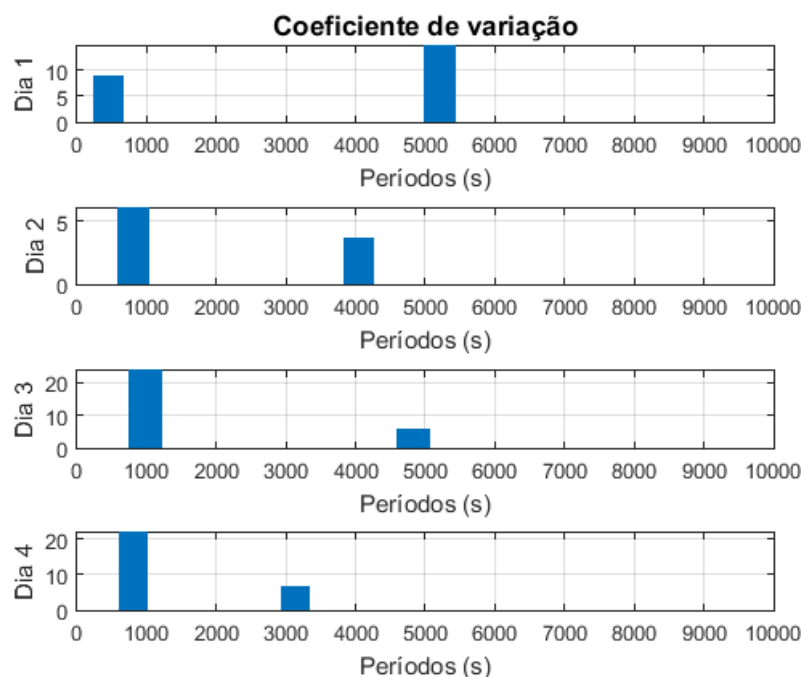
Figura 29 – Oscilações detectadas durante o intervalo analisado. Não foi utilizado agrupamento



A Figura 30 ilustra os resultados obtidos considerando o agrupamento por histograma e as restrições citadas acima. Como é possível observar, oscilações com um período médio entre 500 s e 1.000 s estão presentes nos quatro dias analisados. Além disso, também foram detectadas oscilações que alternam seus períodos médios entre 3.000 s e 5.000 s.

Conclui-se, por meio da Figura 30, que existem oscilações que devem ser investigadas, uma vez que foram identificados períodos semelhantes (entre 500 s e 1.000 s) e com um CVE significativo em todos os dias analisados.

Figura 30 – CVE das oscilações agrupadas durante os 4 dias (são considerados apenas os grupos com os 3 maiores CVEs)



Uma vez descobertas as oscilações que aparecem repetidamente nas análises, o próximo passo consiste em identificar os sinais em que essas oscilações estão presentes. Isso pode ser observado na Figura 31, em que o eixo das abcissas representa os sinais de processo e o eixo das ordenadas o período da oscilação detectada. Os sinais que possuem mais de um círculo sobre a haste foram afetados por mais de uma oscilação.

Nota-se que a oscilação com períodos entre 500 s e 1.000 s afetou os sinais 4, 5, 19 e 20 em pelo menos três dos quatro dias. O sinal 25 também apresentou comportamento oscilatório em três análises, sendo identificadas oscilações com períodos entre 3.000 s e 5.000 s. Dos sinais ilustrados na Figura 25, aqueles que possuem um comportamento oscilatório acentuado (sinais 17 e 25) foram corretamente identificados na análise correspondente ao primeiro dia.

Uma oscilação de aproximadamente 4.000 s afetou os sinais 9, 11, 18 e 29 durante o segundo dia. Esses sinais, ilustrados na Figura 32, de fato apresentaram um comportamento oscilatório durante essa data. Nos demais dias não foram identificadas oscilações nesses sinais, pois os períodos de oscilação T_p foram reprovados no teste de regularidade ou então apresentaram menos de 8 cruzamentos por zero.

Figura 31 – Oscilações detectadas nos 32 sinais analisados durante os 4 dias

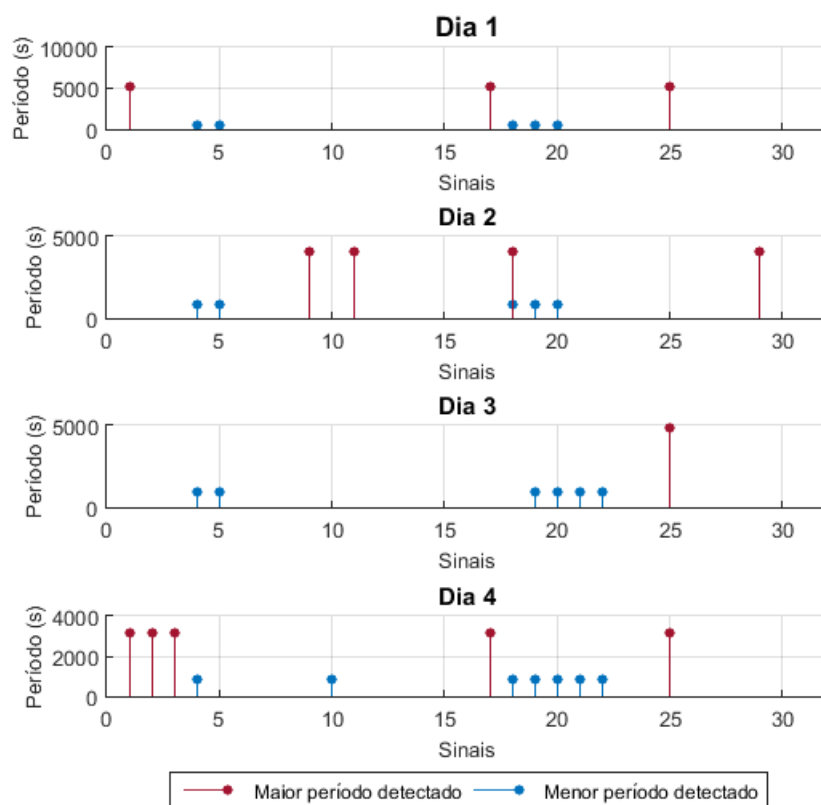
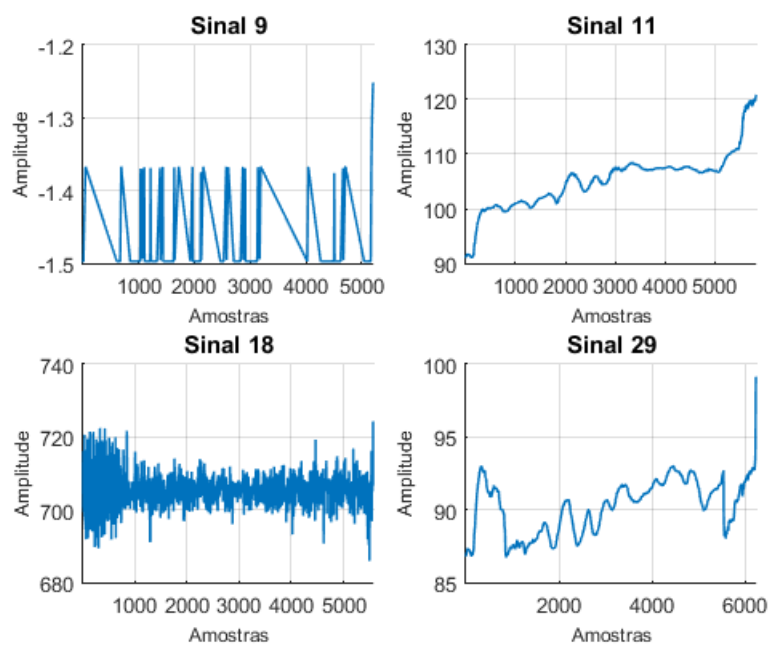


Figura 32 – Sinais de processo 9, 11, 18 e 29 coletados durante o segundo dia. Foram consideradas somente as amostras selecionadas pelo algoritmo de seleção de segmentos

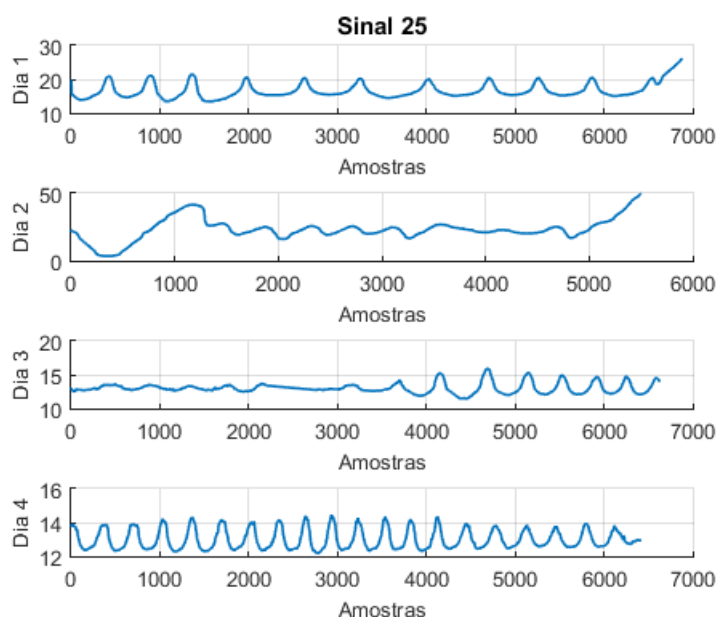


No terceiro dia foi detectada uma oscilação de, aproximadamente, 5.000 s no sinal 25 e uma oscilação com período médio de 1.000 s nos sinais 4, 5, 19, 20, 21 e 22. Já no quarto dia os sinais 2 e 3, que não haviam apresentado comportamento oscilatório nas demais análises, apresentaram uma oscilação com período médio de 3.500, juntamente com os sinais 1, 17 e 25. Também foram detectadas oscilações de 1.000 s nos sinais 4, 10, 18 19, 20, 21 e 22.

Se a oscilação for originada por um problema existente em uma malha de controle, seus sinais apresentarão comportamentos oscilatórios até quando o problema persistir. É possível que ocorra a não detecção dessas oscilações em algumas análises, no entanto elas devem ser identificadas na maioria dos dias estudados. Um exemplo disso é o caso do sinal 25, que não oscila durante o segundo dia, porém contém oscilações nos demais dias analisados. Também vale ressaltar que sinais que apresentam oscilações em um único dia e não são mais diagnosticados como oscilatórios nas demais análises não devem ser considerados durante a investigação de problemas. O que este trabalho propõe é o uso do algoritmo de detecção de oscilações para a identificação de possíveis problemas que prejudicam a eficiência do processo e não a identificação de comportamentos oscilatórios esporádicos.

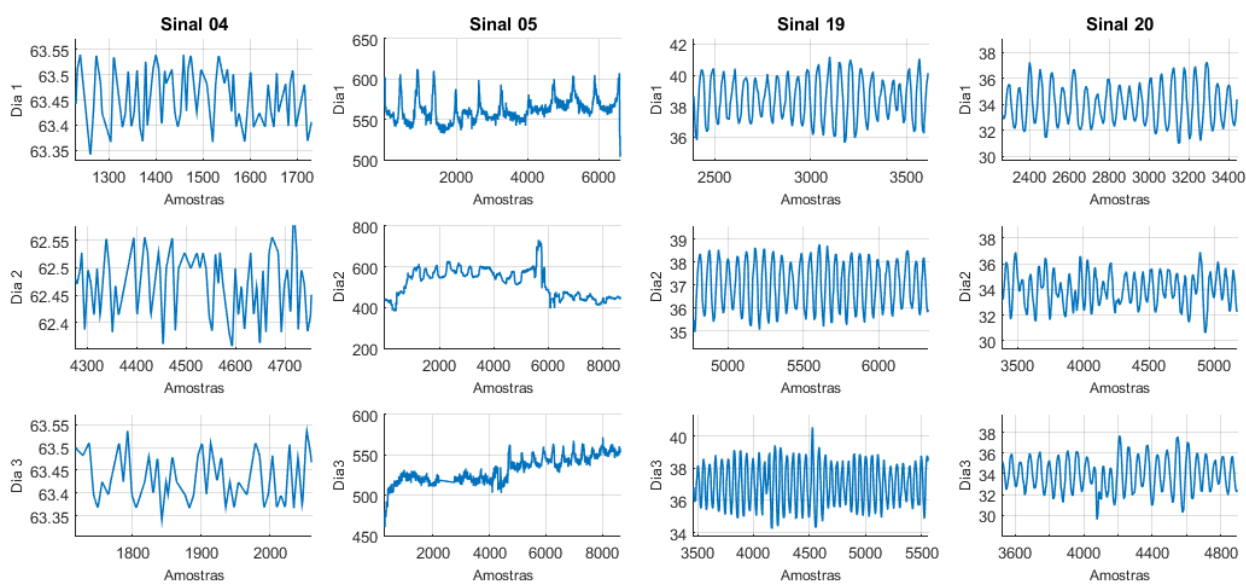
A Figura 33 ilustra o comportamento do sinal 25 ao longo dos quatro dias estudados (foram considerados somente os dados selecionados pelo algoritmo de seleção de segmentos). Em todos os dias foram identificadas oscilações relevantes, com exceção do dia 2. É possível visualizar que, devido à dinâmica do processo, o sinal apresenta variações significativas no seu comportamento diário. Fica claro, por meio da Figura 33, que o sinal de fato apresenta um comportamento oscilatório acentuado.

Figura 33 – Sinal 25 durante os 4 dias analisados. Foram consideradas somente as amostras selecionadas pelo algoritmo de seleção de segmentos



Os sinais 4, 5, 19 e 20 coletados durante os três primeiros dias estão ilustrados na Figura 34. Embora as oscilações presentes nos sinais 4, 19 e 20 possuam pouca variância, esses foram agrupados juntamente com o sinal 5 e outros sinais. A soma do CVE de todos os elementos do grupo resultou em um CVE relevante em todos os três dias analisados.

Figura 34 – Trechos oscilatórios dos sinais 4, 5, 19 e 20 coletados durante todos os Dias 1, 2 e 3



5.4 Apresentação dos resultados no PGA

A análise proposta para o Plug-in desenvolvido está ilustrada na Figura 35. Os ativos de processo são os mesmos utilizados na seção anterior. No entanto, desta vez foram analisados quatorze dias, durante o período de 01/07/2016 a 15/07/2016.

Figura 35 – Análise proposta para o Plug-in desenvolvido




Sugere-se que o usuário comece sua busca por ativos com comportamentos oscilatórios verificando o Relatório Gerencial. Nessa ferramenta, são exibidos os períodos das oscilações mais relevantes. Caso períodos semelhantes sejam detectados repetidamente, o usuário deve observar o CVE associado a tais oscilações. Quanto maior for esse índice, maior será o impacto da oscilação sobre os ativos de processo. Como já explicado na seção 3.2, o CVE está associado à amplitude da oscilação e ao número de sinais afetados por ela.

A Figura 36 ilustra os períodos das oscilações, exibidos no Relatório Gerencial. Uma mesma análise pode identificar até três períodos diferentes. Dessa forma, para haver uma distinção entre esses resultados, classificam-se as oscilações de acordo com a ordem crescente de seus períodos. É possível observar que uma oscilação com um período médio entre 450 s e 1.000 s está presente em todos os dias analisados (Figura 36.a). Também foram detectadas oscilações com períodos médios entre 3.000 s e 7.000 s (Figura 36.c).


A cada análise executada, são exibidos os períodos das oscilações que possuem os três maiores CVEs. No entanto, o algoritmo de detecção de oscilação identificou três períodos distintos em apenas 2 dos 14 dias analisados. Isso não ocorreu nas demais análises, pois a terceira oscilação foi descartada por possuir CVE inferior a 2%. Além disso, as análises executadas nos dias 06/07 a 08/07 apresentaram apenas um período de oscilação, devido à restrição do CVE, novamente. Esses acontecimentos poderiam estar associados ao percentual de retenção dos dados, caso fossem apresentados baixos valores. Entretanto, isso não foi verificado nos dias citados (Figura 38).

O CVE das principais oscilações está ilustrado na Figura 37. Cada curva está associada a um período de oscilação específico. O índice da oscilação de menor período aumenta durante o terceiro dia, apresentando um valor superior a 10% em todas as análises seguintes. Já a oscilação de maior período apresenta um CVE elevado na primeira análise, no entanto esse índice decai ao longo dos demais dias, tornando-se inferior ao CVE da Figura 37.a em todas as outras análises.


Figura 36 – Período das principais oscilações. O gráfico (a) ilustra os menores período identificados em todas as análises; já (b) corresponde ao período intermediário; o gráfico (c) identifica o maior período obtido



(a)




(b)




(c)


Figura 37 – CVE das principais oscilações. O gráfico (a) ilustra o CVE do menor período identificada em uma análise; já (b) representa o índice correspondente ao período intermediário; o gráfico (c) identifica o CVE do maior período obtido em uma análise



(a)




(b)



(c)

A Figura 38 demonstra o percentual de retenção obtido em todas as análises. A média desses resultados é de, aproximadamente, 83%. O pior caso ocorreu no dia 05/07, em que 32% dos dados foram descartados.

Figura 38 - Percentual de retenção calculado em todas as análises



A partir desses resultados, o usuário do PGA deve concluir que existe uma oscilação no processo industrial, uma vez que foram detectados períodos médios relativamente semelhantes em todas as análises (períodos entre 450 s e 1.000 s). Além disso, nota-se na Figura 37 que essa oscilação apresentou o maior CVE na maioria dos dias analisados. Portanto, devido a esses motivos, a oscilação com períodos entre 450 s e 1.000 s é merecedora de maior atenção quando comparada às demais detecções.

O próximo passo consiste em identificar os sinais afetados por essa oscilação para que o usuário determine quais ativos de processo serão investigados com a finalidade de descobrir a causa raiz da perturbação. Para tanto, o usuário deverá escolher uma análise específica e observar os resultados exibidos pelo Visualizador de Resultados. Nessa ferramenta, será exibido o gráfico matricial descrito na seção 4.3.2.1. No entanto, esse recurso ainda está sendo desenvolvido pela empresa TriSolutions e não poderá ser apresentado neste trabalho.

6 CONCLUSÕES E TRABALHOS FUTUROS

Foi apresentado, neste projeto de graduação, um método para detecção e caracterização de oscilações, bem como a sua implementação em ambiente industrial e os resultados alcançados por meio dessa. O bom funcionamento da técnica utilizada depende da escolha de parâmetros, tais como o limiar de potência, o fator de alisamento da PSD e o número de desvios padrão considerados para o agrupamento das oscilações, os quais foram determinados de forma empírica.

Verificou-se neste trabalho que a aplicação do filtro de pré-tratamento proposto pela literatura em sinais que contém *outliers* e distúrbios acentuados provocou a inclusão de componentes oscilatórias, podendo comprometer os resultados do método de detecção de oscilação. A solução encontrada foi a utilização de uma metodologia que seleciona segmentos de dados livres de distúrbios não oscilatórios. Após a aplicação da mesma o uso de filtros não se mostrou mais necessário. A metodologia adotada funcionou de forma adequada quando aplicada a um conjunto de 32 sinais, coletados de um processo industrial.

Foi proposto neste trabalho que os três grupos de oscilação com os maiores CVE sejam tratados de forma prioritária pela equipe de operação da planta. Além disso, também se recomenda a desconsideração de grupos que possuem CVE inferior a 2%. O agrupamento das oscilações por meio de histogramas foi utilizado como um artifício de caráter gerencial para reduzir a quantidade de informações apresentadas ao usuário da plataforma PGA.

O Plug-in desenvolvido foi utilizado para avaliar o comportamento oscilatório de um sistema de controle de um processo real. Foi verificado que um grupo de oscilação apresentou períodos relativamente próximos durante as quatorze análises realizadas. Esse grupo também apresentou a maior variabilidade, sendo assim, propôs-se neste trabalho a investigação dos sinais afetados pelo mesmo.

Vale observar que, no estágio atual do Plug-in, existe uma forte dependência entre seus parâmetros de entrada, tais como o fator de alisamento da PSD e o limiar de potência. Essa característica não é desejada, pois implica na necessidade de acuidade e discernimento por parte do usuário. O ideal seria a utilização de parâmetros mais genéricos possíveis.

A continuação direta deste trabalho seria a utilização do gráfico matricial na plataforma PGA. Outra provável contribuição a ser dada por futuras pesquisas dentro do escopo deste projeto seria a comparação entre as metodologias de agrupamentos apresentadas, bem como o estudo de outras distintas. O agrupamento por histogramas apresentou bons resultados, podendo suprir a necessidade do agrupamento apresentado por Thornhill et al. (2003). Outras técnicas também poderiam ser aplicadas com a finalidade de aprimorar os resultados.

7 BIBLIOGRAFIA

DEPIZZOL, C. F. **Contribuições ao problema de detecção automática de oscilações em malhas de controle**. 2011. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Espírito Santo, Vitória, 2011.

JELALI, M.; HUANG, B. In:_____. **Detection and Diagnosis of Stiction in Control Loops: State of the Art and Advanced Methods**. Londres: Springer. 2009. cap. 4, p. 61-100.

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, n. 2, p. 143-155, fev. 2007.

JUNIOR, R. V.; MUNARO, C. J; SILVEIRA, M. L. Comparação de métodos para detecção de oscilações em processos industriais. **XXI Congresso Brasileiro de Automática**, v. 21, mai. 2016.

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, ago. 2009.

LI, R.; WANG, X. Z. Dimension reduction of process dynamic trends using independent component analysis. **Computers and Chemical Engineering**, v. 26, n.3, p. 467-473, mar. 2002.

KOOPMANS, L. H. The Spectral Analysis of Time Series. **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, jun. 2010.

MUNARO, C. J.; JUNIOR, R. V.; SILVEIRA, M. L.; TARGA, P. E. A. (submetido). Detection of oscillations on highly disturbed industrial plants. **20th World Congress of the International Federation of Automatic Control**, v.20, jul. 2017. Submetido.

SHINSKEY, D. How good are our controller in absolute performance and robustness? **Measurements & Control**, v. 23, n. 4, p. 114-120, mai. 1990.

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, fev. 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, dez. 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, mai. 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, ago. 2005.