



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA  
QUÍMICA



# Avaliação de Métricas de Detecção de Oscilação em Malhas de Controle

*Autor: Guilherme Guedes Machado*

*Orientador: Marcelo Farenzena*

Porto Alegre, dezembro de 13

## Sumário

Agradecimentos	iii
Resumo	iv
Lista de Figuras	v
Lista de Tabelas	vi
1 Introdução	1
2 Revisão Bibliográfica	3
2.1 Auditoria de Malhas de Controle	3
2.2 Auditoria de Desempenho de Malhas de Controles	4
2.2.1 Índices Estocásticos	4
2.2.2 Índices Determinísticos	4
2.3 Auditoria de Instrumentação	4
2.4 Detecção de Oscilações	5
2.4.1 Índice Hagglund (1995) – IAE	6
2.4.2 Índice Thornhill e Hagglund (1997) – IAE e Regularidade	7
2.4.3 Índice Miao (1999) – Autocorrelação	8
2.4.4 Índice Thornhill (2003) - Autocovariância (ACF)	9
2.4.5 Índice de Srinivasan (2007) – EMD modificado	10
2.4.6 Índice de Srinivasan 2012– EMD modificado	11
2.4.7 Índice de Li (2010) – Transformada Cosseno (DCT)	12
2.4.8 Índice de Farenzena – Transformada de Fourier (FFT)	13
3 Metodologia Computacional	15
3.1 Sinais Escolhidos	16
4 Resultados	18
4.1 Índice de Thornhill e Hagglund (1997) – IAE e Regularidade	18
4.2 Índice Miao (1999) – Autocorrelação	19
4.3 Índice Thornhill (2003) - Autocovariância	20
4.4 Índice de Srinivasan (2007) – EMD	21
4.5 Índice de Srinivasan (2012) – EMD	22
4.6 Índice de Índice de Li (2010) –DCT	23
4.7 Índice de Farenzena – Transformada Rápida de Fourier	24
4.8 Comparação Geral dos Índices	26
5 Conclusões e Trabalhos Futuros	27
6 Referências	28
Apêndices	30

## **Agradecimentos**

Primeiramente meu muito obrigado aos meus pais, Jussara e Delcio, pela dedicação e amor sempre presentes, todo o tempo me apoiando e me ajudando a vencer todos os obstáculos que enfrentei.

Às minhas irmãs, Janise e Joseane, pelo companheirismo e amizade, entendendo sempre as minhas ausências e torcendo pelas minhas vitórias. Agradeço também à minha sobrinha afilhada Sofia, por ser tão linda e querida, sempre me trazendo alegria com a sua presença.

Agradeço à Fernanda por ter se tornando essa pessoa tão importante na minha vida, pelos muitos momentos felizes, pelo companheirismo e pela amizade sem fim.

Agradeço aos amigos e familiares que mesmo à distância sempre me apoiaram e torceram por mim.

Agradeço ao Professor Farenzena pela excelente orientação neste trabalho, além da amizade e parceria.

Por fim, agradeço ao Departamento de Engenharia Química pela excelente formação oferecida.

## Resumo

Distúrbios oscilatórios em malhas de controle geram grandes perdas nos setores industriais, que vão desde a perda de qualidade de produto, o aumento no consumo de energia até a redução da confiabilidade de equipamentos. A fim de identificar esses processos oscilatórios, diversos estudos foram feitos nos últimos anos propondo índices de detecção. O presente trabalho tem por objetivo comparar o desempenho de sete índices disponíveis na literatura, apontando suas vantagens e desvantagens. Para realizar essa comparação, os índices foram testados frente a mais de 1200 sinais, abrangendo uma ampla gama de situações, e os resultados foram analisados na forma de porcentagem total de acertos. Dentre todos os índices de detecção de oscilação estudados, o melhor desempenho encontrado foi do índice proposto por Srinivasan (2012). Esse índice, baseado na decomposição empírica de sinais, apresentou um comportamento bastante robusto frente aos sinais oscilatórios, porém frente aos sinais não oscilatórios o mesmo apresentou um resultado apenas razoável. Dois índices baseados em análise espectral de sinais apresentaram um desempenho muito satisfatório frente a sinais não oscilatórios, que foram os índices de Li e de Farenzena. Dentre todos os índices avaliados, nenhum apresentou um resultado realmente confiável para todas as situações. Como perspectiva para próximos trabalhos fica a proposição de um novo método, que aproveite as vantagens dos diversos índices estudados no presente trabalho.

## Lista de Figuras

<b>Figura 2.1:</b> Redução da variabilidade e operação mais próxima de restrições. Extraído de Embiruçu (2004) .....	6
<b>Figura 2.2:</b> Autocovariância em relação ao tempo, mostrando a obtenção do índice R. Extraído de Miao e Seborg (1999). .....	9
<b>Figura 3.2:</b> O sinal $X(t) = 2\text{sen}(2\pi 10t) + 3 \text{sen}(2\pi t) + 0,2t^2$ é decomposto em três funções simples ( $c_1$ , $c_2$ e $r_2$ ). Extraído de Srinivasan et al. (2007) .....	11
<b>Figura 2.4:</b> No alto o sinal original e sua transformada, no meio e abaixo os sinais filtrados e suas respectivas transformadas. ....	13
<b>Figura 3.1:</b> Ambiente criado em <i>Simulink</i> para geração de sinais. ....	15
<b>Figura 4.1:</b> Relação de acerto com a intensidade do ruído para o Índice Thornhill e Hagglund para a função 3. ....	18
<b>Figura 4.2:</b> Relação de acerto com a intensidade do ruído para o Índice de Miao para a função 3. ....	20
<b>Figura 4.3:</b> Relação de acerto com a intensidade do ruído para o Índice de Thornhill ACF para a função 3. ....	20
<b>Figura 4.4:</b> Relação de acerto com a intensidade do ruído para o Índice de Srinivasan (2007) para a função 3. ....	22
<b>Figura 4.5:</b> Relação de acerto com a intensidade do ruído para o Índice de Srinivasan (2012) para a função 3. ....	23
<b>Figura 4.6:</b> Relação de acerto com a intensidade do ruído para o Índice de Li (2010) para a função 3. ....	24
<b>Figura 4.7:</b> Relação de acerto com a intensidade do ruído para o Índice de Farenzena para a função 2. ....	25

## Lista de Tabelas

<b>Tabela 3.1:</b> Valores assumidos pelas constantes das funções base.....	16
<b>Tabela 3.2:</b> Número de sinais avaliados em cada índice.....	17
<b>Tabela 4.1:</b> Desempenho do Índice Thornhill e Hagglund frente aos 10 grupos de funções. .....	18
<b>Tabela 4.2:</b> Desempenho do Índice de Miao frente aos 10 grupos de funções. ....	19
<b>Tabela 4.3:</b> Desempenho do Índice de Thornhill ACF frente aos 10 grupos de funções. ..	21
<b>Tabela 4.4:</b> Desempenho do Índice de Srinivasan (2007) frente aos 10 grupos de funções. .....	22
<b>Tabela 4.5:</b> Desempenho do Índice de Srinivasan (2012) frente aos 10 grupos de funções. .....	23
<b>Tabela 4.6:</b> Desempenho do Índice de Li (2010) frente aos 10 grupos de funções. ....	24
<b>Tabela 4.7:</b> Desempenho do Índice de Farenzena frente aos 10 grupos de funções. ....	25
<b>Tabela 4.8:</b> Comparação geral do desempenho dos índices. ....	26

## 1 Introdução

No setor industrial em geral, o grande aumento dos custos de matérias-primas, energia e recursos naturais, além de regulamentações ambientais mais restritas, vem tornando cada vez mais imperativo o desenvolvimento de novas rotas para o aumento da rentabilidade industrial. A identificação de tendências que levam a uma baixa eficiência de processo de forma rápida e segura tem se tornado indispensável para sistemas produtivos de alto rendimento.

Aumentar a faixa de exploração dos limites operacionais de plantas industriais é algo que vem ao encontro a essa problemática, entretanto a segurança do processo como um todo não pode ser afetada. Quanto menor a variabilidade, ou seja, a dispersão de uma variável em relação a um valor desejado, melhor o desempenho da unidade.

Outra questão que envolve o tema é o grande aumento da automatização dos processos. Nos dias atuais, um pequeno grupo de engenheiros é responsável por centenas até milhares de malhas de controle em uma planta. A taxa de avarias também é um fator considerável, segundo Bialkowski (1993) pelo menos 30% das malhas apresentam oscilação periódica.

Assim, a necessidade do uso de ferramentas que detectem automaticamente ineficiências de processo é crescente. Dentre as causas de aumento de variabilidade, as oscilações periódicas são bastante frequentes, sendo avaliação de métricas de detecção o escopo deste trabalho.

A partir de meados dos anos 90, diversos artigos foram publicados tratando sobre índices de detecção de oscilação. Hagglund (1995) aponta como as principais causas de oscilação em malhas de controle o ajuste inadequado do controlador, problemas em válvulas de controle (agarramento, histerese e banda morta), distúrbios na carga e mudanças na dinâmica da planta.

Após tal trabalho, diversos autores propuseram índices com as mais diferentes metodologias de avaliação. Conforme Srinivasan e Regaswamy (2012), distúrbios periódicos podem ser classificados em três grandes grupos, divididos pela sua forma de análise: regularidade dos cruzamentos da variável de processo com o eixo de referência; autocorrelação da variável de interesse; espectro de densidade da variável.

Apesar da importância do tema, não há na literatura um estudo sistemático comparando os índices para diferentes distúrbios, sendo este o escopo deste trabalho. Foram avaliados sete índices para diferentes tipos de sinais com e sem oscilação, bem como a influência do ruído. O objetivo final deste estudo é mostrar os pontos fortes e fracos desses diferentes índices, e se possível encontrar um que tenha um desempenho melhor e mais homogêneo.

O presente trabalho de conclusão de curso é dividido como segue: no capítulo 2 é feita uma revisão geral, que vai desde auditoria em malhas de controle até auditoria de instrumentação, fazendo uma abrangência mais aprofundada dos estudos que foram desenvolvidos para detecção de oscilação em malhas de controle; no capítulo 3 está estruturada a metodologia para o desenvolvimento da análise, bem como uma explanação sobre os sinais utilizados para fazer a avaliação dos índices; no capítulo 4 são apresentados os resultados obtidos para cada índice individualmente e também uma

comparação entre desempenho geral de todas as métricas avaliadas; no capítulo 5 são feitas as ponderações finais bem como de rotas para trabalhos futuros. No apêndice deste trabalho, são apresentados os códigos de implementação dos índices avaliados no *software* Matlab®.



## 2 Revisão Bibliográfica

### 2.1 Auditoria de Malhas de Controle

De maneira geral, auditoria é um trabalho de análise cuidadosa e metódica do funcionamento de um sistema, com objetivo de examinar se ele opera de acordo com as características planejadas e se foi implementado em conformidade com os objetivos propostos. Também tem como finalidade quantificar os limites de desempenho dos itens que serão validados.

É um procedimento que se faz pelo monitoramento de alguns parâmetros chave que representam a qualidade do sistema, constatando eventuais mudanças em certas características e tomando ações voltadas à manutenção da condição desejada.

No contexto de um sistema de controle, envolve-se um estudo detalhado sobre funcionamento do processo e seus requisitos de qualidade, verificação do funcionamento de dispositivos (atuadores, sensores e controladores), estudo sobre as interações existentes entre as malhas de controle e levantamento sobre todas as ações que podem interferir no funcionamento da malha de controle.

Técnicas de auditoria podem ser aplicadas em diversas áreas de uma indústria, seja em equipamentos, linhas de produção, válvulas, controladores, etc. A avaliação pode ser feita remotamente em sistemas somente de supervisão bem como de maneira invasiva através de métodos implementados diretamente em uma central de controle.

Hugo (2006) aponta os requisitos necessários de uma técnica de monitoramento em uma malha de controle:

- 1- Deve ser independente de perturbações e do *setpoint*;
- 2- Não deve requer testes na planta;
- 3- Deve ser passível de implementação automática;
- 4- Deve requerer mínima especificação da dinâmica do processo;
- 5- A métrica deve fornecer uma medida não arbitrária, ou seja, deve comparar a qualidade do processo com algum padrão absoluto;
- 6- Deve ser sensível apenas ao desajuste do controlador, incertezas de modelo ou problemas de equipamento;
- 7- Deve fornecer um indicativo do porquê de o controlador estar desempenhando insatisfatoriamente.

Os principais tipos de auditoria em sistemas de controle são: avaliação de desempenho da malha, avaliação de instrumentos e avaliação de distúrbios periódicos.

## 2.2 Auditoria de Desempenho de Malhas de Controles

O funcionamento deficitário em malhas de controle é muito comum em ambientes industriais. Seus efeitos introduzem excesso de variação através do processo, reduzindo assim a operabilidade de equipamentos, aumentando os custos de produção e afetando a qualidade do produto final. Segundo Jelali (2006), mais de 60% dos controladores industriais tem problemas de desempenho.

O objetivo principal dessa análise é fornecer um procedimento que entregue informações para serem avaliadas pelo pessoal responsável, podendo-se assim quantificar a performance do sistema de controle implantado.

Com a finalidade de obter essa quantificação do desempenho de malhas, foram desenvolvidos diversos índices de avaliação. Estes índices podem ser divididos em duas categorias: estocásticos e determinísticos.

### 2.2.1 Índices Estocásticos

Os índices estocásticos mais largamente estudados são aqueles baseados na variância mínima de controle como referência. Seu princípio é comparar a variância da variável controlada com aquela que seria obtida utilizando um controlador de variância mínima. Teoricamente, um controlador de variância mínima é aquele capaz de remover todos os efeitos de um distúrbio após o tempo morto do processo deixando apenas ruído branco. Com isso é obtido um limite inferior de variabilidade, ou máximo desempenho (Harris, 1989). Harris em seu trabalho de 1989 propôs um índice que se utiliza da abordagem da variância mínima, abrindo horizontes para diversos trabalhos posteriores, como por exemplo, os feitos por Desborough e Harris (1992), Huang et al. (1997).

São índices que podem ser obtidos usando dados comuns de plantas e podem ser implementados de maneira não intrusiva. Alguns métodos, por exemplo, utilizam algoritmos baseados em mínimos quadrados.

### 2.2.2 Índices Determinísticos

São índices que não consideram a aleatoriedade do processo. Muitos desses indicadores são fundamentados na resposta da malha a uma mudança na referência, tais como: tempo de acomodação, tempo de subida, taxa de decaimento, distância do *setpoint (offset)*, entre outros. Existem muitos índices determinísticos que se baseiam no erro de controle calculado, como por exemplo, IAE (Integral do Erro Absoluto), ISE (Integral do Erro Quadrático), entre outros.

## 2.3 Auditoria de Instrumentação

O principal foco das auditorias de instrumentação são as válvulas e seus componentes.

Segundo estudos, cerca de 30% das malhas de controle encontradas na indústria oscilam devido a problemas relacionados às válvulas de controle (Garcia, 2008). Dentre os vários tipos de não linearidade presentes em válvulas com posicionador, o agarramento é o tipo mais comum (Choudhury *et al.*, 2006). Ainda podem-se citar outros problemas

frequentes em válvulas, como por exemplo, histerese (ou folga) e banda morta. Dentro desse contexto, técnicas que detectam e diagnosticam esse tipo de problema são muito importantes dentro de indústrias de processos, com grande destaque nos setores petroquímico e celulósico.

Um dos primeiros trabalhos desenvolvidos para detectar agarramento em válvulas foi feito por Horch (1999). O objetivo desse trabalho foi realizar uma correlação entre os sinais de saída (OP) e valor presente (PV) da variável, com essa informação é possível verificar o atraso desses dois sinais e a partir daí identificar a presença ou ausência de agarramento na válvula.

Outras técnicas foram se desenvolvendo com o passar dos anos. Choudhury *et al.* (2006) desenvolveram um método precursor capaz de obter quantitativamente o atrito em uma válvula. Esse trabalho baseia-se no comportamento elipsoidal do diagrama de fase PV x OP, calculando o grau de agarramento através da área da elipse encontrada.

Outros diversos trabalhos na área podem ser citados, como os de Stenman *et al.* (2003), Rossi e Scali (2005), Xia *et al.* (2005) e Scali e Ghelardoni (2008).

## 2.4 Detecção de Oscilações

Uma malha de controle é dita oscilatória quando sua variável controlada apresenta um padrão regular de desvios em torno da referência de controle. No contexto de controle estatístico de processos, diz-se que este é um comportamento determinístico, ou seja, existe uma causa raiz detectável para a variabilidade da malha.

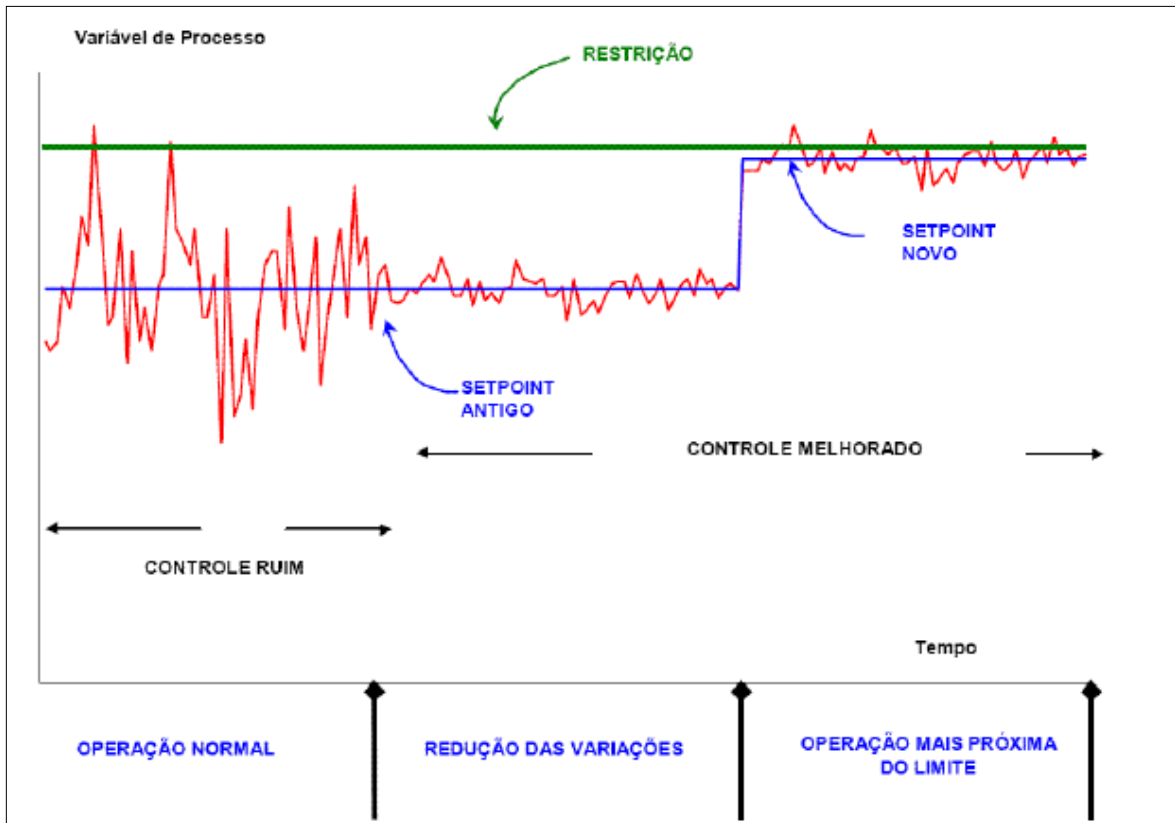
Nos últimos anos, diversos estudos foram feitos com o objetivo de identificar distúrbios periódicos em sistemas de controle. Oscilações em malhas aumentam a variabilidade na qualidade do produto (gerando mais produtos fora de especificação), além de afetar a parte mecânica de equipamentos e instrumentos. Em um estudo publicado por Jelali (2006), mais de 4000 malhas de indústrias de diferentes segmentos foram auditadas e chegou-se a conclusão que mais da metade delas poderiam ser significativamente melhoradas somente com a eliminação de distúrbios periódicos.

É importante detectar e diagnosticar esse tipo de problema, pois uma planta operando mais próxima de seus limites é mais lucrativa do que uma que opera em condições mais conservadoras devido à amplitude das oscilações de processo. Para exemplificar essa afirmação é apresentada a Figura 2.1, nela pode-se observar que inicialmente com um sistema de controle desajustado, o *setpoint* era definido de forma conservadora, após, com um melhor ajuste, é possível operar de forma mais próxima dos limites operacionais.

Segundo Hagglund (1995), as principais causas de oscilações em malhas de controle são:

- Ajuste inadequado do controlador
- Problemas em válvulas de controle (agarramento, histerese, banda morta)
- Distúrbios na carga

- Mudança na dinâmica da planta



**Figura 2.1:** Redução da variabilidade e operação mais próxima de restrições. Extraído de Embiruçu (2004).

A partir de meados dos anos 90, muitos autores começaram a trabalhar para desenvolver métricas de detecção de oscilação. Porém, não há uma definição matemática formal para esse fenômeno em sistemas de controle. Em geral, conforme Srinivasan e Regaswamy (2012), distúrbios periódicos são identificados principalmente pela análise dos seguintes indicadores:

- Regularidade dos cruzamentos da variável de saída do processo com o eixo de referência (em inglês *zero crossings*)
- Autocorrelação da variável de saída do processo
- Espectro de densidade da variável de saída do processo

A seguir, será apresentado um maior detalhamento de alguns dos principais índices de detecção de oscilação em malhas de controle.

#### 2.4.1 Índice Hagglund (1995) – IAE

É baseado na discretização da integral absoluta do erro de um sinal de controle. Por erro do sinal de controle se entende como a diferença do valor desejado (SP) e do valor real (PV). A integral absoluta do erro é definida pela expressão 2.1:

$$IAE_{(i)} = \int_{t_i}^{t_{i+1}} |y(t)| dt \quad (2.1)$$

onde  $y(t)$  é o erro do sinal de interesse e  $t_i$  e  $t_{i+1}$  são os tempos sucessivos entre dois cruzamentos em zero de  $y(t)$ .

O valor dessa integral deve ser comparado com um valor limite, que é definido a partir da constante de tempo da malha. Hagglund sugere em seu trabalho de 1995 a seguinte expressão para o limite de detecção:

$$IAE_{(i)} \geq \frac{a\tau}{\pi} \quad (2.2)$$

onde  $a$  é definido como 1% do faixa de operação do sinal e  $\tau$  é a constante de tempo da malha.

Se o valor da  $IAE_{(i)}$  ultrapassar o valor limite mais do que 10 vezes, o sinal é considerado oscilatório. Esse é o critério utilizado por Hagglund no artigo base desse método.

Esse índice pode ser implementado de forma a analisar os dados de uma malha em tempo real, podendo então indicar um comportamento oscilatório assim que for ultrapassada a situação limite.

#### 2.4.2 Índice Thornhill e Hagglund (1997) – IAE e Regularidade de Oscilações

É um complemento ao índice anterior, proposto por Thornhill e Hagglund (1997). Esse trabalho visa incluir, além da IAE do sinal, a regularidade das oscilações. Então, é proposto um novo limite de detecção:

$$\frac{IAE_{(i)}}{\Delta T_{(i)}\sigma} \geq \xi \quad (2.3)$$

onde  $\Delta T_{(i)}$  é o período entre dois cruzamentos em zero,  $IAE_{(i)}$  é a integral absoluta do erro entre esses dois cruzamentos em zero,  $\sigma$  é uma estimativa do valor r.m.s. (valor quadrático médio) do ruído do sinal e  $\xi$  é o limite de detecção.

Nesse trabalho foram utilizados os valores de referências do artigo de Thornhill e Hagglund (1997), sendo  $\sigma$  igual a 1 e  $\xi$  igual a  $2/\pi$ .

A regularidade dos desvios é analisada pelo uso do fator de regularidade,  $R$ , que é baseado na relação entre os intervalos adjacentes de dois desvios,  $\Delta k$ , como é definido na equação 2.4:

$$R_i = \frac{\Delta k_{i+1}}{\Delta k_i} \quad (2.4)$$

A fim de mensurar a oscilação do sinal, é definido o fator adimensional  $q$ :

$$q = \frac{R_m}{\sigma_R} \quad (2.5)$$

onde,  $R_m$  é a média dos valores de  $R_i$  e  $\sigma_R$  é o desvio padrão de  $R_i$ .

Se o valor de  $q$  ultrapassar um valor limite, o sinal é declarado como oscilatório. No artigo base desse índice é usado o valor limite de 1,3.

#### 2.4.3 Índice Miao (1999) – Autocorrelação

Miao e Seborg (1999) apresentaram um método baseado na função da autocorrelação. Essa técnica analisa a taxa de decaimento da função autocorrelação frente ao tempo, propondo um índice,  $R$ , que relaciona a altura de dois picos subsequentes. É importante ressaltar que se o sinal é oscilatório a função autocorrelação (ou autocovariância) também o será e com o mesmo período. Uma vantagem da utilização dessas funções estatísticas é a redução do impacto dos ruídos, pois teoricamente, um ruído branco tem um valor de autocorrelação igual à zero, o que torna a visualização gráfica mais clara.

Esse é um método baseado no conceito estatístico da autocorrelação. A autocorrelação é a medida de quanto o valor de uma variável está vinculada com seus valores vizinhos, ou seja, a dependência entre eles. A definição formal, utilizada por Miao e Seborg (1999), é a seguinte:

$$p_k = \frac{\sum_{t=1}^{N-k} (Z_t - Z_m)(Z_{t+k} - Z_m)}{\sum_{t=1}^N (Z_t - Z_m)^2} \quad (2.6)$$

onde:

$p_k$  = função autocorrelação

$Z_t$  = valor da variável  $Z$  no tempo  $t$

$Z_{t+k}$  = valor da variável  $Z$  no tempo  $t+k$

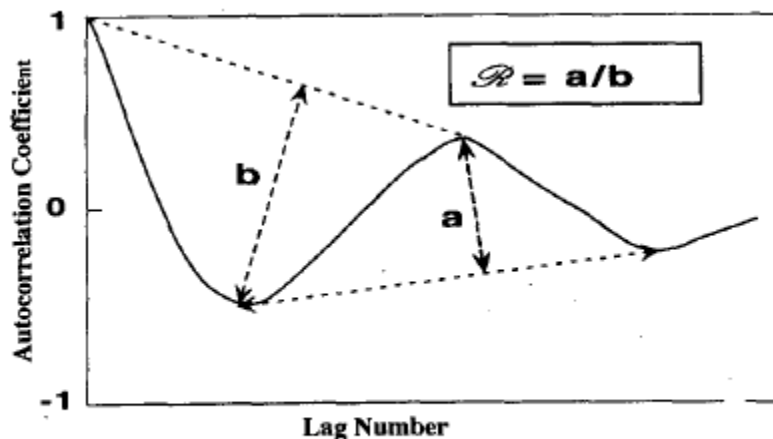
$Z_m$  = valor médio da variável  $Z$  no período de interesse.

A autocorrelação varia entre -1 e 1, sendo  $p_k$  igual a 1 correlação perfeita,  $p_k$  igual a -1 anticorrelação perfeita, e  $p_k$  igual a zero, ausência de correlação.

A aplicação dessa técnica é bastante vantajosa, pois além de ser simples não requer dados de controle da planta, sendo necessários somente dados de operacionais a serem analisados, como, por exemplo, o valor presente da variável de interesse em relação ao tempo.

O índice  $R$  é obtido através da autocorrelação, da qual se analisa a taxa de decaimento da função frente ao tempo, como é mostrado na Figura 2.2. Quando a função avaliada não apresentar ao menos dois pontos de mínimo, o índice já caracteriza a função como não oscilatória ( $R=0$ ).

O índice  $R$  apresenta automaticamente, através de implementação em software adequado, se os dados analisados apresentam comportamento oscilatório ou não. É preciso definir um limite para o valor de  $R$  em relação à oscilação. Esta definição é relativamente subjetiva e depende da estratégia de controle utilizada pelo usuário. Seguindo a sugestão proposta por Miao e Seborg (1999), neste trabalho foi usado o valor de 0,5 como limite, ou seja, se  $R$  maior que o limite o sistema é declarado como oscilatório.



**Figura 2.2:** Autocovariância em relação ao tempo, mostrando a obtenção do índice R. Extraído de Miao e Seborg (1999).

#### 2.4.4 Índice Thornhill (2003) - Autocovariância (ACF)

Método baseado na ferramenta estatística da autocovariância, de onde se obtém o índice de avaliação de oscilação, “r”. A fundamentação teórica foi extraída do trabalho proposto por Thornhill et al. (2003).

A covariância é definida como a medida de como duas variáveis variam conjuntamente (Milone, 2009). A autocovariância representa o grau de interdependência entre a mesma variável, porém com um atraso de tempo.

Esta é uma técnica que explora a regularidade do intervalo de tempo entre duas passagens da função pelo zero. Uma das vantagens de se analisar a função autocovariância (ACF), ao invés do sinal propriamente dito, é que o impacto do ruído do sinal é reduzido, tornando assim mais clara a identificação de um processo oscilatório.

A principal dificuldade da aplicação desse método é encontrar o período de oscilação, pois se há a presença de mais de um distúrbio oscilatório, haverá uma sobreposição de sinais. Ou seja, cada nova interferência influencia o sistema como um todo.

Para obtenção do índice de detecção de oscilação “r”, foi utilizada a definição de Thornhill de 2003:

$$r = \frac{1}{3} \times \frac{\overline{T_P}}{\sigma_{T_P}} \quad (2.7)$$

onde:

$\overline{T_P}$ : média dos períodos de oscilação

$\sigma_{T_P}$ : desvio padrão dos períodos de oscilação

Segundo o critério proposto por Thornhill et al (2003), valores de  $r$  maiores que 1 indicam a presença de ciclos oscilatórios bem definidos.

#### 2.4.5 Índice de Srinivasan (2007) – EMD modificado

De maneira geral, faz-se uma decomposição de um sinal mais complexo em vários sinais simples que possuem média constante, removendo deles a média não constante. Após a obtenção dessas funções decompostas, os autores sugerem o uso de uma técnica simples de detecção de oscilação, como o índice de autocorrelação de Thornhill (2003), com o objetivo de analisar se elas apresentam ou não um comportamento oscilatório.

Métrica proposta por Srinivasan *et al.* (2007) é baseada na decomposição empírica de sinais (EMD). A EMD é uma técnica oriunda do trabalho de Huang *et al.* (1998) que se baseia no desmembramento de sinais compostos em vários sinais simples, através da remoção de médias não constantes. Obtendo-se os sinais simplificados é possível obter os seus diferentes períodos oscilatórios bem como suas amplitudes.

O método proposto tem três características principais:

- A análise é toda feita no domínio do tempo.
- A forma do sinal é preservada, somente sendo removida a sua média não constante.
- Apresenta bom desempenho frente oscilações múltiplas.

Os passos para decomposição de uma função foram propostos por Huang *et al.* (1998). Considere um sinal  $y(t)$  que será dividido em duas funções, uma de alta frequência  $c(t)$  e outra de baixa  $r(t)$ :

$$y(t) = c(t) + r(t) \quad (2.8)$$


A fim de se obter essas funções, segue-se o seguinte procedimento iterativo:

1. Identificar todos os máximos e mínimos da função  $y(t)$
2. Usar uma função de interpolação, uma *spline* cúbica, por exemplo, para conectar todos os pontos de máximo. Esta será a função “envelope” superior, chamada de  $y_u(t)$ .
3. Realizar o procedimento similar para os pontos de mínimo, obtendo-se assim a função  $y_l(t)$ .
4. A função  $r(t)$  será a média desses dois sinais,  $r_1(t) = (y_u(t) + y_l(t)) / 2$ .
5. Obter a função  $c_1$  através de  $c_1(t) = y(t) - r_1(t)$ .
6. Iterar os passos 1 a 5 até que  $c_i(t)$  encontre um valor limite. Huang et al. (1998) propõem um valor limite entre 0,2 e 0,3 de desvio padrão entre dois resultados consecutivos de  $c_i(t)$ .

Uma vez extraída  $c_1(t)$ , o resíduo  $r_1(t)$  é decomposto em  $r_1(t) = c_2(t) + r_2(t)$ , onde  $c_2(t)$  representa a segunda função simplificada de média constante. De maneira geral, o processo iterativo acabará quando a função residual não puder mais ser decomposta em outras mais simples.



A Figura 3.2 apresenta uma representação da decomposição de um sinal pelo método proposto.



**Figura 2.3:** O sinal  $X(t) = 2\text{sen}(2\pi 10t) + 3\text{sen}(2\pi t) + 0,2t^2$  é decomposto em três funções simples ( $c_1$ ,  $c_2$  e  $r_2$ ). Extraído de Srinivasan *et al.* (2007).

A modificação proposta por Srinivasan *et al.* (2007) é reduzir o processo iterativo de obtenção para todas as funções decompostas. A sugestão é separar somente o distúrbio oscilatório predominante, assim aumentando a agilidade do método. A modificação na implementação é feita para que somente a primeira função oscilatória decomposta seja analisada.

Depois de feita a decomposição, utiliza-se um método de detecção simples a fim de validar a procedimento de diagnóstico de oscilação. No trabalho proposto por Srinivasan *et al.* (2007) foi utilizado o índice de Thornhill *et al.* (2003) para complementar a análise.

#### 2.4.6 Índice de Srinivasan (2012)– EMD modificado

É uma modificação ao índice anterior, na qual se faz o uso do mesmo procedimento até a obtenção das funções decompostas. Esse novo método propõe o uso de dois coeficientes avaliativos extras, o coeficiente normalizado de correlação ( $\lambda$ ) e o índice esparsividade ( $S$ , *Sparseness index*).

A determinação do coeficiente normalizado de correlação ( $\lambda_i$ ) das funções decompostas é obtida a partir do coeficiente de correlação ( $m_i$ ) entre cada função decomposta e a função original, dada por:

$$\lambda_i = \frac{m_i}{\text{máx}(m_i)} \quad (2.9)$$

$$m_i = \frac{\text{Covariância}(\text{sinal original}, \text{sinal decomposto}(i))}{\sqrt{\text{Variância}(\text{sinal original}) * \text{Variância}(\text{sinal decomposto}(i))}} \quad (2.10)$$

$$i = 1 \dots L$$

onde L é o número de funções decompostas.

Dentre as funções decompostas, as que apresentarem um  $\lambda$  maior que 0,5 serão consideradas significantes e analisadas na próxima etapa. As menores que esse limite serão descartadas.

As funções decompostas com  $\lambda$  maior que 0,5, serão avaliadas pelo índice de esparsividade, que é dado por:

$$S = \frac{\sqrt{N} - \left( \frac{\sum_{j=1}^N |x_j|}{\sqrt{\sum_{j=1}^N |x_j|^2}} \right)}{\sqrt{N} - 1} \quad (2.11)$$

$$j = 1 \dots N$$

onde x é o vetor da Transformada de Fourier do sinal decomposto,  $x_j$  é um componente individual do vetor x e N é o comprimento do vetor x.

As funções decompostas que apresentarem um índice de esparsividade maior que 0,5 serão consideradas de interesse e avaliadas no próximo passo. A última etapa para detectar oscilação deste índice de Srinivasan é avaliar as funções de interesse aplicando o índice de Thornhill (2003), baseado na covariância dos sinais. Se a função atender os requisitos de todas estas etapas ela será considerada oscilatória.

#### 2.4.7 Índice de Li (2010) – Transformada Discreta de Cosseno (DCT)

Este método é baseado na transformada discreta da função cosseno. A ideia principal é analisar os componentes do sinal no domínio da frequência, destacando assim os picos mais representativos do sinal. É um índice que apresenta uma série de vantagens, como por exemplo:

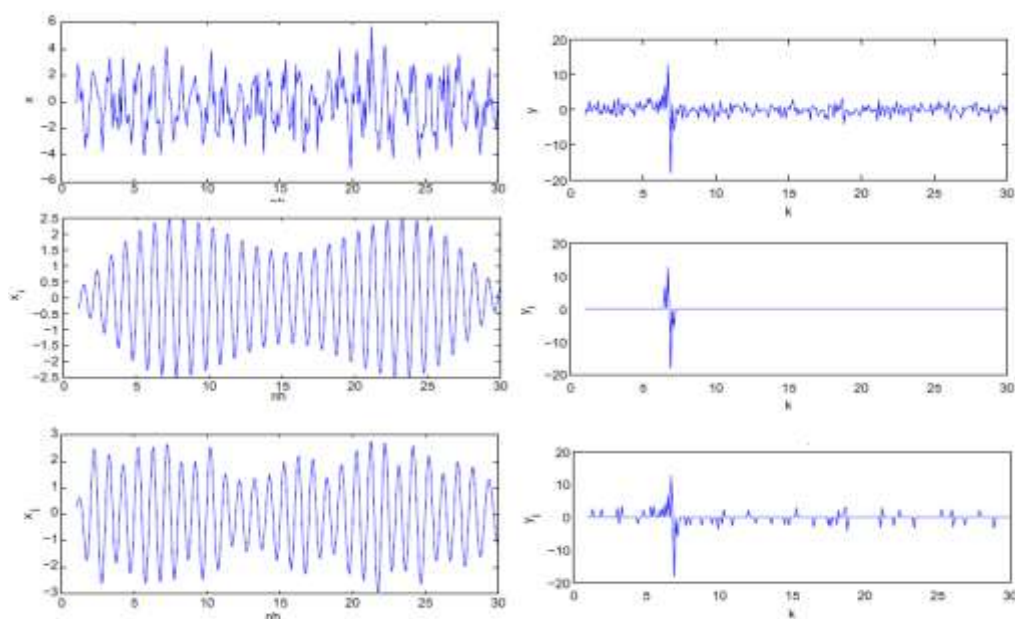
- Não apresenta necessidade de uso de dados de planta ou conhecimentos adicionais do sistema de controle.
- Robustez frente aos ruídos.
- Possibilidade de automação sem intervenções humanas.

Os passos para obtenção do índice são dispostos da seguinte maneira, através da análise de uma função genérica  $x(n)$ :

1. Remover a média do sinal original e aplicar a transformada discreta de cosseno sobre o sinal, obtendo a função  $y(k)$ .

2. Calcular o limite superior para o sinal, definido como três vezes o desvio padrão de  $y(k)$ . Todos os valores de  $y(k)$  abaixo desse limite são zerados, obtendo-se assim a função  $y_i(k)$ .
3. Calcular a transformada inversa de  $y_i(k)$ , obtendo o sinal  $x_i(n)$ .
4. No sinal  $x_i(n)$ , calcular o período médio de cruzamentos em zero e o desvio padrão dos mesmos. Se a razão do período médio e desvio padrão for superior a 3, então essa função  $x_i(n)$  é considerada oscilatória.
5. Repetir os passos 2-4 modificando o limite superior para um desvio padrão. Obter, assim, a mesma razão período médio e desvio padrão nessa segunda situação.
6. Se em ambos os casos, as funções obtidas foram declaradas oscilatórias então o sinal  $x(n)$  também o será.

Na figura 2.4 são representados os sinais obtidos pelos passos acima para uma função senoidal com a adição de ruído branco. Na Figura 2.4 é representada a função original ( $x$ ) e sua respectiva transformada ( $y$ ), no centro, a função extraída a partir da transformada filtrada em três desvios padrões e a sua transformada, e por fim, a função obtida a partir da transformada filtrada em apenas um desvio padrão e sua transformada.



**Figura 2.4:** No alto o sinal original e sua transformada, no meio e abaixo os sinais filtrados e suas respectivas transformadas.

#### 2.4.8 Índice de Farenzena (Submetido para publicação) – Transformada Rápida de Fourier (FFT)

É uma métrica baseada na Transformada Rápida de Fourier do sinal de interesse. A ideia principal é, a partir do espectro de frequência, identificar os picos de maior intensidade.

A fim de se verificar se o sinal é oscilatório ou não, os seguintes passos são seguidos:

1. Aplica-se uma Transformada Rápida de Fourier no sinal de interesse  $y(t)$ , obtendo-se o vetor  $X$ .
2. Obter a média e o desvio padrão da vetor  $X$ .
3. O limite de detecção é estabelecido conforme a equação 2.12. Se esse limite é ultrapassado o sinal é declarado como oscilatório.

$$\text{Limite} = \bar{X} + 4\sigma_X \quad (2.12)$$

onde,  $\bar{X}$  é o valor médio de  $X$  e  $\sigma_X$  é o desvio padrão de  $X$ .

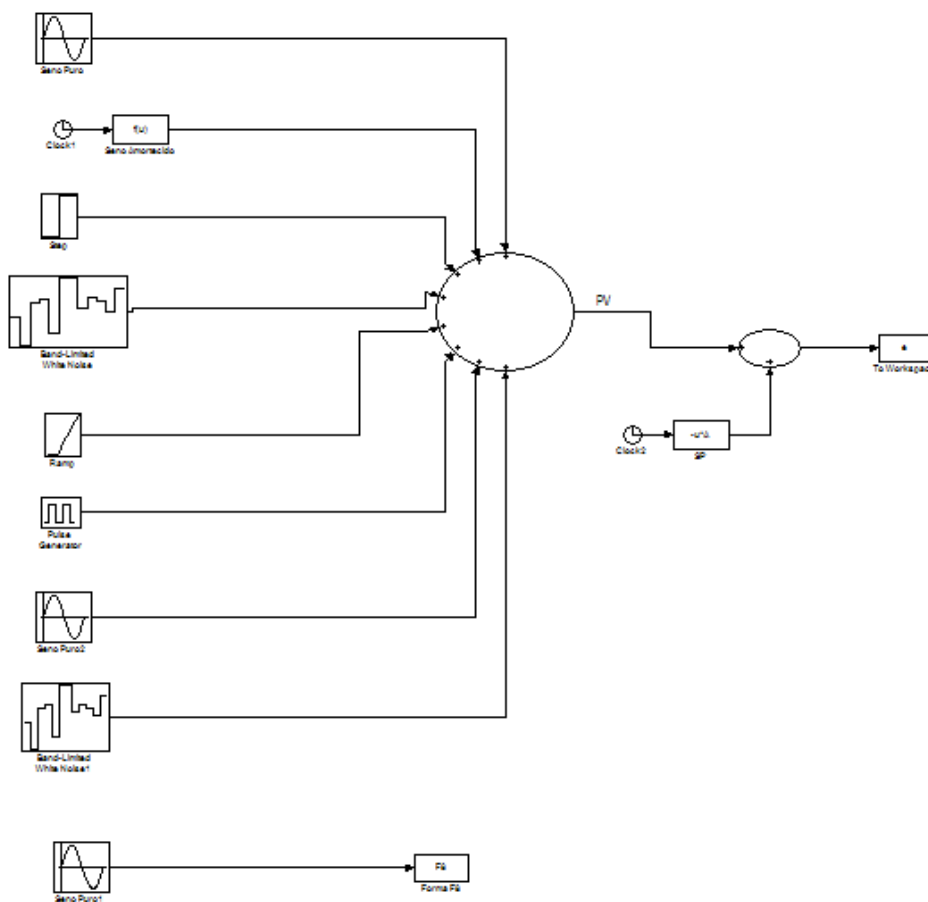
Essa métrica está em processo de desenvolvimento e sendo testada pela primeira vez no presente trabalho. Como ainda não foi feita a publicação, o código de implementação não será anexado.

### 3 Metodologia Computacional

Com o objetivo de realizar uma comparação sistemática acerca dos indicadores de oscilação periódica, alguns índices foram escolhidos para implementação no *software* Matlab® 2009, sendo eles:

- Índice de Thornhill e Hagglund (1997) – IAE e Regularidade de Oscilações;
- Índice de Miao (1999) – Autocorrelação;
- Índice de Thornhill (2003) – Autocovariância;
- Índice de Srinivasan (2007) – EMD;
- Índice de Srinivasan (2012) – EMD;
- Índice de Li (2010) – DCT ;
- Índice de Farenzena – FFT.

Todos foram testados frente ao mesmo grupo de sinais, padronizando a comparação, com o objetivo de se obter uma quantificação do desempenho dos mesmos. Para facilitar a implementação dos sinais frente a todos os índices, foi usada a ferramenta *Simulink* do Matlab®. A Figura 3.1 mostra a representação da interface criada para geração de sinais, com a qual foi possível a criação de diversos sinais, como senos, rampas, sinais amortecidos, sinais com e sem ruído etc.



**Figura 3.1:** Ambiente criado em *Simulink* para geração de sinais.

O tempo de todas as análises foi de 1000 unidades de tempo. O código de implementação de cada método está no apêndice do presente trabalho.

### 3.1 Sinais Escolhidos

Os sinais foram divididos em 10 grupos gerados a partir de uma função base. As funções escolhidas estão representadas abaixo:

$$\text{Função 1} = A \operatorname{sen}\left(\frac{2\pi x}{P1}\right)$$

$$\text{Função 2} = \operatorname{sen}\left(\frac{2\pi x}{P1}\right) + \operatorname{sen}\left(\frac{2\pi x}{P2}\right)$$

$$\text{Função 3} = e^{\left(\frac{-x}{C}\right)} \operatorname{sen} \frac{2\pi x}{P3}$$

$$\text{Função 4} = e^{\left(\frac{-x}{C}\right)} \operatorname{sen}\left(\frac{2\pi x}{100}\right) + \operatorname{sen}\left(\frac{2\pi x}{P2}\right)$$

$$\text{Função 5} = \text{pulso retangular}(A, P4, \text{Centrado em } 0)$$

$$\text{Função 6} = e^{\left(\frac{-x}{C}\right)} \operatorname{sen}(2\pi x/50) + \text{pulso retangular}(A = 1, P4, \text{Centrado em } 0)$$

$$\text{Função 7} = \operatorname{sen} \frac{2\pi x}{P1} + \operatorname{sen} \frac{2\pi x}{P2} + 0,01x$$

$$\text{Função 8} = \left( \operatorname{sen} \frac{2\pi x}{P1} \right) \left( \operatorname{sen} \frac{2\pi x}{P2} \right)$$

$$\text{Função 9} = Ax + \text{Ruído Branco}$$

$$\text{Função 10} = \text{Constante} + \text{Ruído Branco}$$

Onde cada constante das funções foi variada conforme a Tabela 3.1.

**Tabela 3.1:** Valores assumidos pelas constantes das funções base.

A	P1	P2	P3	P4	C	Ruído
<b>0,01</b>	8	10	5	10	50	0,01
<b>0,1</b>	16	20	15	20	100	0,1
<b>1</b>	32	40	60	40	200	1
<b>3</b>	64	50	90	50	250	5
<b>10</b>	128	100	200	100	500	10

Cada função possui 2 constantes que foram avaliadas para os 5 valores diferentes, conforme mostrado na Tabela 3.1. Por exemplo, a função 1 possui as constantes de amplitude (A) e período (P1) que irão ser avaliadas para cada uma situação, formando assim um grupo de 25 sinais diferentes. Na Tabela 3.2, é exposto o número total de sinais avaliados para cada índice, lembrando que as funções 9 e 10 são as não-oscilatórias.

A fim de validar o desempenho de cada índice frente ao ruído, em um segundo momento foram inseridos 5 ruídos brancos de intensidades diferentes em cada grupo de

função, gerando assim 125 sinais ruidosos para cada grupo. A introdução dos ruídos foi feita através da função “*Band-Limited White Noise*” do *Simulink* do Matlab®. As intensidades dos mesmos podem ser vistas na Tabela 3.1.

Para as duas últimas funções (9 e 10), foi feita a variação de apenas uma constante e do ruído para a função 9 e para a função 10 apenas o ruído. Para aumentar o número de sinais avaliados, foram usadas 10 intensidades diferentes de ruído, que foram: 0,01; 0,05; 0,1; 0,5; 1; 2,5; 5; 10; 20 e 30.

**Tabela 3.2:** Número de sinais avaliados em cada índice.

	Sem ruído	Com Ruído	Total
<b>Função 1</b>	25	125	150
<b>Função 2</b>	25	125	150
<b>Função 3</b>	25	125	150
<b>Função 4</b>	25	125	150
<b>Função 5</b>	25	125	150
<b>Função 6</b>	25	125	150
<b>Função 7</b>	25	125	150
<b>Função 8</b>	25	125	150
<b>Função 9</b>	5	50	55
<b>Função 10</b>	1	10	11
<b>Total</b>	<b>206</b>	<b>1060</b>	<b>1266</b>

As funções que possuem ruído foram testadas em duas diferentes situações, uma sem pré-tratamento e outra uma filtragem com a função “*ldfilt*” do Matlab®. Nessa função foi usada a frequência de corte de 0,1 rad/s e ordem 2.

O desempenho de cada índice foi obtido com o resultado do mesmo frente a todos os sinais diferentes.

A fim de fazer uma análise mais detalhada sobre o comportamento de cada função ao se aumentar o ruído, foi feita um relação apresentada na forma de gráfico do comportamento de cada índice com o aumento da intensidade do ruído. Para uma função escolhida, foi construído o gráfico do acerto do índice em relação à intensidade do ruído. Com isso, foi possível averiguar a influência da intensidade do ruído em relação ao desempenho de cada índice.

## 4 Resultados


O desempenho de cada índice será apresentado separadamente. O resultado obtido será apresentado na forma de porcentagem de acertos frente ao total de sinais testados. No fim deste capítulo, será apresentada uma comparação entre a performance de cada índice.

### 4.1 Índice de Thornhill e Hagglund (1997) – IAE e Regularidade de Oscilações

A síntese dos resultados do Índice de Thornhill e Hagglund é apresentada na Tabela 4.1. A Figura 4.1 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.

**Tabela 4.1:** Desempenho do Índice Thornhill e Hagglund frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	64,0%	87,2%	84,8%
<b>Função 2</b>	100,0%	100,0%	100,0%
<b>Função 3</b>	80,0%	92,0%	92,0%
<b>Função 4</b>	100,0%	100,0%	100,0%
<b>Função 5</b>	60,0%	87,2%	84,0%
<b>Função 6</b>	100,0%	100,0%	100,0%
<b>Função 7</b>	100,0%	98,4%	100,0%
<b>Função 8</b>	56,0%	79,2%	84,0%
<b>Função 9</b>	100,0%	30,0%	30,0%
<b>Função 10</b>	100,0%	0,0%	0,0%
<b>Média acertos</b>	86,0%	77,4%	77,5%



**Figura 4.1:** Relação de acerto com a intensidade do ruído para o Índice Thornhill e Hagglund para a função 3.

Para sinais sem ruído, o índice apresentou um bom desempenho, chegando a 86% de acerto. As principais dificuldades encontradas foram em relação às funções 5 e 8.

A inserção de ruído aos sinais não diminuiu os acertos para as funções oscilatórias (1-8), pois considerando somente as oito primeiras funções a porcentagem de acertos passou dos 90%. O problema foi para as funções não oscilatórias (9 e 10), que apresentaram grande presença de falsos positivos.



Como pode ser visto na Figura 4.1, o aumento da intensidade do ruído aumentou a detecção oscilações para a função 3. Uma possível causa para esse comportamento é que com o aumento da intensidade do ruído a integral do erro calculada aumenta também, por vezes ultrapassando o limite de detecção. Entretanto, esse comportamento afeta o desempenho do índice, aumentando a incidência de falsos positivos como pode ser visto na Tabela 4.1 para as funções 9 e 10.

O pré-tratamento dos dados praticamente não modificou os resultados, sendo então desnecessária essa filtragem inicial.

É possível afirmar que uma das causas dos erros encontrados esteja relacionada ao limite máximo da integral do erro, pois para esse parâmetro foi escolhido um valor único, independente das características do sinal. Como descrito no Capítulo 2, a escolha desse parâmetro depende de características da malha de controle em questão, o que dificulta esse tipo de análise. Caso fosse realizada uma pré-análise dos grupos de função e feita uma escolha dos parâmetros limites específicos para cada função, possivelmente o desempenho do índice em questão aumentaria.

#### 4.2 Índice Miao (1999) – Autocorrelação


A síntese dos resultados do Índice de Miao é apresentada na Tabela 4.2. A Figura 4.2 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.

**Tabela 4.2:** Desempenho do Índice de Miao frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	100,0%	100,0%	96,0%
<b>Função 2</b>	100,0%	88,0%	95,2%
<b>Função 3</b>	88,0%	92,8%	98,4%
<b>Função 4</b>	100,0%	92,8%	95,2%
<b>Função 5</b>	100,0%	96,0%	100,0%
<b>Função 6</b>	96,0%	92,0%	81,6%
<b>Função 7</b>	100,0%	82,4%	92,8%
<b>Função 8</b>	96,00%	92,8%	96,0%
<b>Função 9</b>	100,0%	0,0%	0,0%
<b>Função 10</b>	100,0%	0,0%	0,0%
<b>Média acertos</b>	98,0%	73,7%	75,5%

O índice de Miao apresentou um excelente desempenho frente a sinais sem ruído, apresentando uma média de acertos de 98%. As principais falhas do índice ocorreram frente a sinais com amortecimento senoidal.

O desempenho do índice caiu quando o ruído foi inserido na análise. O acerto geral para os sinais oscilatórios (funções 1-8) pré-tratados com o filtro foi superior a 90%, enquanto que sem a pré-filtragem o desempenho ligeiramente superior. Porém, o desempenho para sinais não oscilatórios (9 e 10) com ruído foi ruim, apresentando 100% de falsos positivos.



**Figura 4.2:** Relação de acerto com a intensidade do ruído para o Índice de Miao para a função 3.


No artigo base, os autores pontuam a eficiência do método frente a ruídos, pois o mesmo faz uso da função autocorrelação para calcular o índice, e não do sinal propriamente dito. De certa forma, esse fato foi comprovado, pois os resultados apresentados pelos sinais sem filtragem foram superiores aos com filtragem e não muito inferiores aos sem ruído (descartando os resultados das funções 9-10).

Na Figura 4.2, observa-se que a inserção de ruído aumenta a detecção de oscilações para o índice em questão. Esse comportamento é um problema, pois quando a análise é feita para um sinal não-oscilatório o comportamento foi o mesmo, aumentando o erro por falso positivo, o que pode ser visto na Tabela 4.2 para os últimos dois sinais apenas comparando os resultados com e sem ruído.

Outra questão a ser avaliada é o período de análise do sinal. Esse ponto pôde ser observado pelo desempenho do índice frente aos sinais amortecidos. Esses grupos de funções (3 e 6) apresentaram um desempenho inferior aos demais devido ao longo período da análise em relação ao tempo de amortecimento do sinal, pois o mesmo atinge um estado quase estacionário, mascarando a intensidade do fator R do índice.

### 4.3 Índice Thornhill (2003) - Autocovariância (ACF)

A síntese dos resultados do Índice de Thornhill ACF é apresentada na Tabela 4.3. A Figura 4.3 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.



**Figura 4.3:** Relação de acerto com o ruído para o Índice de Thornhill para a função 3.

**Tabela 4.3:** Desempenho do Índice de Thornhill ACF frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	100,0%	92,0%	88,8%
<b>Função 2</b>	96,0%	87,2%	56,7%
<b>Função 3</b>	84,0%	72,8%	72,0%
<b>Função 4</b>	88,0%	86,4%	64,8%
<b>Função 5</b>	100,0%	90,4%	89,6%
<b>Função 6</b>	100,0%	92,0%	72,8%
<b>Função 7</b>	100,0%	92,8%	64,0%
<b>Função 8</b>	96,0%	65,6%	64,8%
<b>Função 9</b>	0,0%	0,0%	0,0%
<b>Função 10</b>	0,0%	0,0%	0,0%
<b>Média acertos</b>	76,4%	67,9%	57,4%

O índice em questão apresentou um excelente desempenho frente a sinais oscilantes (grupos de função 1-8) sem ruído, apresentando uma média de acertos de 95,5%. A principal limitação deste índice foi a taxa de falsos positivos, para as funções 9 e 10, que ficou em 100%. Esse problema poderia ser parcialmente corrigido, bastando a inserção de uma condicional no índice (se não há cruzamentos, “r” assume o valor de zero). Como nada é sugerido no artigo base, essa melhoria não foi inserida na implementação.

Para todos os sinais houve uma piora significativa de desempenho com a introdução de ruídos. Algo que pode ser visto na Tabela 4.3, é o desempenho geral pior para os sinais não filtrados em relação aos filtrados. No artigo base, os autores afirmam que o método é robusto frente aos ruídos, o que não foi verificado neste trabalho.

Em relação aos sinais não oscilatórios (funções 9 e 10), o mesmo tipo de problema que ocorreu em sinais sem ruídos pode ser observado em sinais ruidosos, que é a forte presença de falsos positivos.

A Figura 4.3 mostra que para este índice não há uma relação clara da influência do ruído no desempenho do índice. O que pode ser observado é a maior estabilidade dos resultados quando é feita uma filtragem dos dados.

#### 4.4 Índice de Srinivasan (2007) – EMD

A síntese dos resultados do Índice de Srinivasan (2007) é apresentada na Tabela 4.4. A Figura 4.2 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.


O índice em questão apresentou um desempenho acima da média frente aos sinais oscilantes sem ruído, apresentando 98,5% de acertos. Para sinais sabidamente não oscilatórios (funções 9 e 10) essa métrica se apresentou bastante falha, apresentando falsos positivos. O mesmo problema pode ser observado para sinais com ruído.

O índice manteve o bom rendimento para os sinais oscilantes com ruído, apresentando acertos próximos a 100%. O problema apareceu para os sinais ruidosos não oscilantes que apresentaram sempre o resultado de falso positivo. É possível que esse

problema seja oriundo da forma de desmembramento dos sinais, que “força” de certa maneira a formação de sinais decompostos oscilantes. Não é clara a motivação da proposta de uma modificação nesse método pelos mesmos autores cinco anos depois, mas é possível imaginar que o objetivo fosse diminuir esse tipo de erro.

**Tabela 4.4:** Desempenho do Índice de Srinivasan (2007) frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	100,0%	100,0%	99,2%
<b>Função 2</b>	100,0%	100,0%	100,0%
<b>Função 3</b>	88,0%	98,4%	100,0%
<b>Função 4</b>	100,0%	100,0%	98,4%
<b>Função 5</b>	100,0%	100,0%	100,0%
<b>Função 6</b>	100,0%	100,0%	100,0%
<b>Função 7</b>	100,0%	99,2%	100,0%
<b>Função 8</b>	100,0%	100,0%	100,0%
<b>Função 9</b>	0,0%	0,0%	0,0%
<b>Função 10</b>	0,0%	0,0%	0,0%
<b>Média acertos</b>	78,8%	79,8%	79,8%



**Figura 4.4:** Relação de acerto com a intensidade do ruído para o Índice de Srinivasan (2007) para a função 3.


Na Figura 4.4, observa-se que a inserção de ruídos aumenta a detecção de oscilações para o índice em questão. O mesmo tipo de análise feita para o Índice de Miao pode ser feita nesse caso, que o aumento da intensidade do ruído torna o índice mais propício a encontrar distúrbios oscilatórios. Também é possível verificar pela Tabela 4.4 e Figura 4.4 que a inserção de filtro não proporcionou melhorias ao método.

#### 4.5 Índice de Srinivasan (2012) – EMD

A síntese dos resultados do Índice de Srinivasan (2012) é apresentada na Tabela 4.5. A Figura 4.5 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.

**Tabela 4.5:** Desempenho do Índice de Srinivasan (2012) frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	100,0%	100,0%	99,2%
<b>Função 2</b>	100,0%	99,2%	100,0%
<b>Função 3</b>	88,0%	96,0%	96,0%
<b>Função 4</b>	100,0%	100,0%	96,0%
<b>Função 5</b>	100,0%	100,0%	100,0%
<b>Função 6</b>	100,0%	100,0%	100,0%
<b>Função 7</b>	100,0%	99,2%	99,2%
<b>Função 8</b>	100,0%	100,0%	98,4%
<b>Função 9</b>	100,0%	60,0%	65,6%
<b>Função 10</b>	100,0%	51,2%	52,0%
<b>Média acertos</b>	98,8%	90,6%	90,6%

**Figura 4.5:** Relação de acerto com a intensidade do ruído para o Índice de Srinivasan (2012) para a função 3.

Nos sinais não ruidosos, o índice em questão apresentou um desempenho acima da média, com 98,8% de acertos e uma boa robustez para evitar falsos negativos. O pior desempenho foi frente ao grupo 3, provavelmente devido ao amortecimento senoidal que foi muito rápido em alguns casos em comparação ao período de análise. Esse mesmo problema aconteceu, em menor grau, nos sinais com ruído.

O índice de Srinivasan de 2012 manteve o excelente rendimento para os sinais oscilantes com ruído, apresentando acertos próximos a 96%. O problema em sinais ruidosos não oscilatórios (9 e 10) foi amenizado em relação ao índice anterior do mesmo autor, porém continuou apresentando significativos erros. Em linhas gerais essa métrica se tornou mais robusta que a anterior para evitar falsos positivos.

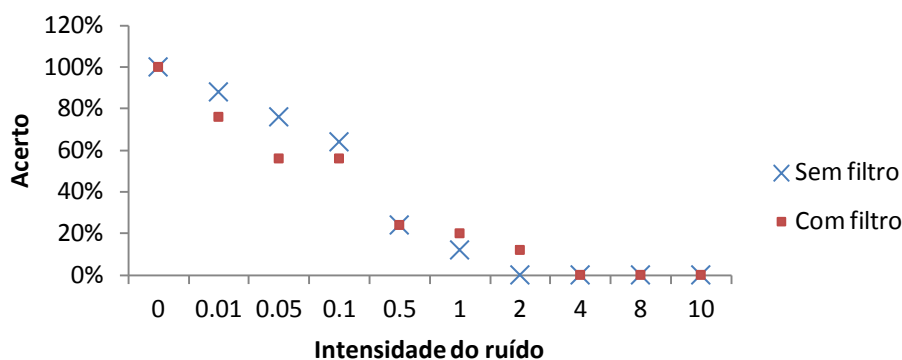
A Figura 4.5 mostra a mesma tendência dos índices de Miao e de Srinivasan (2007), onde a mesma análise pode ser feita. A inserção de uma pré-filtragem de dados não se mostrou eficaz para essa métrica.

#### 4.6 Índice de Li (2010) – Transformada Discreta de Cosseno (DCT)

A síntese dos resultados do Índice de Li (2010) é apresentada na Tabela 4.6. A Figura 4.6 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do ruído introduzido para o grupo de funções 3.

**Tabela 4.6:** Desempenho do Índice de Li (2010) frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	40,0%	27,2%	28,8%
<b>Função 2</b>	24,0%	31,2%	10,4%
<b>Função 3</b>	100,0%	30,4%	32,8%
<b>Função 4</b>	56,0%	28,0%	10,4%
<b>Função 5</b>	0,0%	14,4%	0,0%
<b>Função 6</b>	0,0%	12,8%	0,0%
<b>Função 7</b>	4,0%	15,2%	0,0%
<b>Função 8</b>	60,0%	33,6%	51,2%
<b>Função 9</b>	100,0%	100,0%	100,0%
<b>Função 10</b>	100,0%	100,0%	100,0%
<b>Média acertos</b>	48,4%	39,3%	33,4%

**Figura 4.6:** Relação de acerto com a intensidade do ruído para o Índice de Li (2010) para a função 3.

Esta foi a métrica que apresentou os piores resultados. Tanto para sinais ruidosos quanto para os não ruidosos o índice se mostrou ineficaz. Porém, algo que pode ser apontado com uma característica desse trabalho é a eficiência frente aos sinais não oscilantes.

Wang *et al.* (2013) realizaram uma análise quantitativa do índice em questão, apontando diversas falhas e problemas de desempenho em determinadas situações. Segundo os autores, foram verificadas falhas, tanto na detecção de falsos positivos quanto de falsos negativos. Neste mesmo trabalho, foram feitas sugestões e propostas de melhorias à metodologia usada por Li *et al.* (2010).

A Figura 4.6 mostra que com o aumento da intensidade do ruído o desempenho cai gradativamente, comportamento diferente dos cinco primeiros índices estudados. Esse fenômeno pode ser explicado pela forma de cálculo dessa métrica, que faz uso da análise espectral do sinal que tem maior dificuldade em separar os picos em presença de ruídos mais intensos.


#### 4.7 Índice de Farenzena – Transformada Rápida de Fourier (FFT)

A síntese dos resultados do Índice de Farenzena é apresentada na Tabela 4.7. A Figura 4.7 apresenta a relação da porcentagem de acerto do índice em relação à intensidade do

ruído introduzido para o grupo de funções 2 (não foi usada a função 3, como para os outros índices, devido ao baixo desempenho deste frente à essa função).

**Tabela 4.7:** Desempenho do Índice de Farenzena frente aos 10 grupos de funções.

	Sem Ruído	Ruído, Com Filtro	Ruído, Sem Filtro
<b>Função 1</b>	100,0%	56,0%	61,6%
<b>Função 2</b>	88,0%	52,0%	63,2%
<b>Função 3</b>	12,0%	0,0%	0,0%
<b>Função 4</b>	16,0%	0,0%	0,0%
<b>Função 5</b>	100,0%	10,4%	26,4%
<b>Função 6</b>	100,0%	5,6%	21,6%
<b>Função 7</b>	100,0%	64,8%	80,8%
<b>Função 8</b>	28,0%	23,2%	53,6%
<b>Função 9</b>	100,0%	100,0%	100,0%
<b>Função 10</b>	100,0%	100,0%	100,0%
<b>Média acertos</b>	74,4%	41,2%	50,7%



**Figura 4.7:** Relação de acerto com a intensidade do ruído para o Índice de Farenzena para a função 2.

Para os sinais sem ruído o desempenho foi razoável. O índice apresentou acerto de 100% para vários grupos de função, porém teve um desempenho baixo para algumas funções (3, 4 e 8), o que comprometeu a média, que ficou em 74,4% de acertos.

A inserção de ruídos nos sinais fez com que o desempenho caísse bastante. É fácil observar esse comportamento, observando a Figura 4.7, que mostra a queda de rendimento do índice com o aumento da intensidade do ruído.

O mesmo problema encontrado para sinais sem ruído foi observado de forma mais acentuada para os sinais com ruído, o que prejudicou o desempenho geral do índice.

Um diferencial desse índice é robustez frente aos sinais não oscilatórios (funções 9 e 10). Mesmo com inserção de ruídos o mesmo se mostrou bastante eficiente, ao contrário da maioria das métricas avaliadas.

#### 4.8 Comparação Geral dos Índices

Na Tabela 4.8 é apresentado o resumo do desempenho de todos os índices testados nesse trabalho. Nessa é exposto o melhor resultado de cada índice em relação ao ruído, ou seja, com ou sem pré-filtragem de dados.

**Tabela 4.8:** Comparação geral do desempenho dos índices.

	Sem Ruído	Com Ruído	Média
Thornhill e Hagglund (1997)	86,0%	77,5%	81,7%
Miao (1999)	98,0%	75,5%	86,8%
Thornhill (2003)	76,4%	67,9%	72,2%
Srinivasan (2007)	98,8%	79,8%	89,3%
Srinivasan (2012)	98,8%	90,6%	<b>94,7%</b>
Li (2010)	48,4%	39,3%	43,8%
Farenzena	74,4%	50,7%	62,6%

Uma das falhas mais recorrentes nas diferentes métricas estudadas foi presença de falsos positivos. Uma razão para isso talvez seja a forma com que os índices são concebidos, sendo “forçados” a identificar comportamentos oscilatórios em sinais, algo que nem sempre é verdadeiro. Os dois índices que levaram vantagem nessa questão foram os de Li e Farenzena, que apresentaram resultados bons frente aos sinais não oscilatórios. Ambos possuem uma metodologia parecida, fazem uso da análise no domínio da frequência dos sinais.

A maioria das métricas em questão poderia ter obtido um desempenho final melhor se fosse feita uma pré-análise dos sinais, porém com isso se fugiria do escopo deste trabalho que é avaliar todos os índices em iguais condições. Em alguns casos, o período de análise foi muito longo em relação à oscilação do sinal ou em outros a intensidade do ruído adulterou os resultados. Entretanto, esse era o objetivo do trabalho, comparar os todos em índices de forma homogênea, sempre os avaliando frente aos mesmos sinais.

O índice que se mostrou mais eficiente no geral foi o de Srinivasan (2012), que apresentou uma robustez muito boa frente aos sinais oscilatórios e um desempenho apenas razoável frente aos sinais não oscilatórios.



## 5 Conclusões e Trabalhos Futuros

No presente trabalho, uma revisão sistemática acerca de diversos métodos de detecção de oscilação em malhas de controle foi feita. O objetivo geral do mesmo foi alcançado, que era realizar uma comparação crítica dos índices avaliados, mostrando suas vantagens e desvantagens. Foram escolhidos, para isso, sete métodos, que foram: Índice de Thornhill e Hagglund (1997), Índice de Miao (1999), Índice de Thornhill (2003), Índice de Srinivasan (2007), Índice de Srinivasan (2012), Índice de Li (2010) e Índice de Farenzena.

Para realizar essa comparação, todos os índices foram testados frente a mais de 1200 sinais, a fim de abranger uma ampla gama de comportamentos. Com auxílio de um ambiente criado em Matlab®, foi criada uma metodologia de geração de sinais com a qual foi possível realizar diversas variações, como por exemplo, aumento do ruído, frequência de oscilação e amplitude do sinal.

O índice que apresentou o melhor desempenho foi de Srinivasan (2012), baseado na decomposição empírica de sinais. Esse apresentou um comportamento muito robusto quando testado em sinais oscilatórios, conseguindo 98,9% de acertos, porém quando em presença de sinais não oscilatórios os acertos caíram para cerca de 60%. Mesmo assim, a sua média geral de acertos (94,7%) foi a mais elevada dentre os sete índices testados.

Todos os índices testados, exceto os dois últimos, apresentaram o mesmo tipo de falha: grande quantidade de falsos positivos. Ao contrário, os dois últimos índices avaliados (Li e Farenzena) foram eficientes frente a esse tipo de problema, porém foram deficientes em sinais oscilatórios.

A concepção de cálculo dos índices tem uma relação muito forte com os resultados encontrados. Como o objetivo de uma métrica de detecção de oscilação é achar oscilações, muitas metodologias são desenvolvidas com uma forte tendência de descobrir esse tipo de comportamento, o que é problemático. Ao contrário, as técnicas baseadas em análise espectral não apresentaram essas características, o que as levou a falhar em alguns casos de oscilação, porém mostrando sempre resultados corretos quando não há presença de distúrbios periódicos.

Uma rota promissora que surge com o término desse trabalho é a da elaboração de um novo índice de detecção de oscilações que conjugue as vantagens das métricas estudadas. Uma metodologia que pode apresentar bom desempenho é uma mescla, por exemplo, de um índice baseado em análise espectral com um baseado na decomposição de sinais e regularidade de cruzamentos em zero.

## 6 Referências

BIALKOWSKI, W. L. **Dreams versus reality: A view from both sides of the gap.** . Pulp and Paper Canada, 94:11 1993.

CHOUDHURY, M. A. A. S. et al. Automatic detection and quantification of stiction in control valves. **Control Engineering Practice**, v. 14, n. 12, p. 1395-1412, // 2006.

DESBOROUGH, L.; HARRIS, T. Performance assessment measures for univariate feedback control. **Canadian Journal of Chemical Engineering**, v. 70, n. 6, p. 1186-1197, // 1992.

EMBIRUÇU, M. **Avaliação Econômica de Projetos de Controle e Automação. Cursode Especialização em Instrumentação, Automação, Controle e Otimização deProcessos Contínuos.** Escola Politécnica UFBA: 2004.

GARCIA, C. Comparison of friction models applied to a control valve. **Control Engineering Practice**, v. 16, n. 10, p. 1231-1243, 10// 2008. ISSN 0967-0661.

HARRIS, T. J. Assessment of control loop performance. **Canadian Journal of Chemical Engineering**, v. 67, n. 5, p. 856-861, // 1989.

HORCH, A. A simple method for detection of stiction in control valves. **Control Engineering Practice**, v. 7, n. 10, p. 1221-1231, // 1999.

HUANG, B.; SHAH, S. L.; KWOK, E. K. Good, bad or optimal? Performance assessment of multivariable processes. **Automatica**, v. 33, n. 6, p. 1175-1182, // 1997.

HUANG, N. E. et al. The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 454, n. 1971, p. 903-995, // 1998.

HUGO, A. J. Performance assessment of single-loop industrial controllers. **Journal of Process Control**, v. 16, n. 8, p. 785-794, 9// 2006. ISSN 0959-1524.

HÄGGLUND, T. A control-loop performance monitor. **Control Engineering Practice**, v. 3, n. 11, p. 1543-1551, // 1995.

JELALI, M. An overview of control performance assessment technology and industrial applications. **Control Engineering Practice**, v. 14, n. 5, p. 441-466, // 2006.

LI, X. et al. The DCT-based oscillation detection method for a single time series. **Journal of Process Control**, v. 20, n. 5, p. 609-617, 6// 2010. ISSN 0959-1524.

MIAO, T.; SEBORG, D. E. Automatic detection of excessively oscillatory feedback control loops. 1999. p.359-364.

MILONE, G. ***Estatística geral e aplicada***. São Paulo-SP: Centage Learning, 2009.

ROSSI, M.; SCALI, C. A comparison of techniques for automatic detection of stiction: Simulation and application to industrial data. **Journal of Process Control**, v. 15, n. 5, p. 505-514, // 2005.

SCALI, C.; GHELARDONI, C. An improved qualitative shape analysis technique for automatic detection of valve stiction in flow control loops. **Control Engineering Practice**, v. 16, n. 12, p. 1501-1508, // 2008.

SRINIVASAN, B.; RENGASWAMY, R. Automatic oscillation detection and characterization in closed-loop systems. **Control Engineering Practice**, v. 20, n. 8, p. 733-746, // 2012.

SRINIVASAN, R.; RENGASWAMY, R.; MILLER, R. A modified empirical mode decomposition (EMD) process for oscillation characterization in control loops. **Control Engineering Practice**, v. 15, n. 9, p. 1135-1148, 9// 2007. ISSN 0967-0661.

STENMAN, A.; GUSTAFSSON, F.; FORSMAN, K. A segmentation-based method for detection of stiction in control valves. **International Journal of Adaptive Control and Signal Processing**, v. 17, n. 7-9, p. 625-634, // 2003.

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, // 2003.

THORNHILL, N. F.; HÄGGLUND, T. Detection and diagnosis of oscillation in control loops. **Control Engineering Practice**, v. 5, n. 10, p. 1343-1354, 10// 1997. ISSN 0967-0661.

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, 5// 2013. ISSN 0967-0661.

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, // 2005.

## 7 Apêndice

### 7.1 Índice de Thornhill e Haggund (1997)

```
function oscila =IAE1997(y)

%cruzamento por zero
aux = find(y>0);
aux2 = diff(aux);
aux3 = find(aux2~=1);
crosspoints = [1;1];
for i=1:length(aux3)
crosspoints = [crosspoints;aux(aux3(i));aux(aux3(i)+1)];
end

% cálculo das áreas acima (A) e abaixo (B) de zero
for i=1:floor(length(crosspoints)/2)-1
A(i) = sum(abs(y(crosspoints(2*i):crosspoints(2*i+1))));
B(i) = sum(abs(y(crosspoints(2*i+1):crosspoints(2*i+2))));
end
%calculo do indice IAE
for i=1:min([length(A) length(B)])
    IAEp(i)=A(i);
    IAEn(i)=B(i);
end

limite=(a*tau/pi);%%limite IAE

%intervalo entra picos
for i=1:floor(length(crosspoints)/2)-1
Tsup(i) = abs((crosspoints(2*i+1)-crosspoints(2*i)));
Tinf(i) = abs((crosspoints(2*i+2)-crosspoints(2*i+1)));
end

for i=1:length(Tsup)
    R1(i)=Tsup(1+1)/Tsup(i);
end
for i=1:length(Tinf)
    R2(i)=Tinf(1+1)/Tinf(i);
end
%média e desvio padrao dos intervalos
M1=mean(R1);M2=mean(R2);M=(R1+R2)/2;
DP1=std(R1);DP2=std(R2);DP=(DP1+DP2)/2;
q=M/DP;

if max(IAEp)> limite | max(IAEn)> limite & q>1.3
    oscila = 1;
else
    oscila = 0;
end
```

### 7.2 Índice de Miao (1999)

```
function oscila = miao(y)

%função autocorrelação
pk=xcorr(y,'coeff');
pk = pk(round(length(pk)/2):end);
deriv = diff(pk);

p1 = 0;
p2 = 0;
```

```

for i=1:length(deriv)-1
    if deriv(i) > 0 & deriv(i+1) < 0
        p1 = p1 + 1;
        maxs(p1) = (i + 1);
    end
    if deriv(i) < 0 & deriv(i+1) > 0
        p2 = p2 + 1;
        mins(p2) = (i + 1);
    end
end

for i = 1:p1-1
    xx = (maxs(i):maxs(i+1));
    dy = (pk(maxs(i+1)) - pk(maxs(i)))/(length(xx)-1);
    yy = pk(maxs(i)):dy:pk(maxs(i+1));

    if maxs(1) < mins(1)
        for j = 1:length(xx)
            dist(j) = sqrt(((xx(j) - mins(i))^2+(yy(j) -
pk(mins(i)))^2);
        end
        [distmin,xdistmin] = min(dist);
        dmin(i) = distmin;
    else
        for j = 1:length(xx)
            dist(j) = sqrt(((xx(j) - mins(i+1))^2+(yy(j) -
pk(mins(i+1)))^2);
        end
        [distmin,xdistmin] = min(dist);
        dmin(i) = distmin;
    end
end

for i = 1:p2-1
    xx = (mins(i):mins(i+1));
    dy = (pk(mins(i+1)) - pk(mins(i)))/(length(xx)-1);
    yy = pk(mins(i)):dy:pk(mins(i+1));

    if maxs(1) > mins(1)
        for j = 1:length(xx)
            dist(j) = sqrt(((xx(j) - maxs(i))^2+(yy(j) -
pk(maxs(i)))^2);
        end
        [distmax,xdistmax] = min(dist);
        dmax(i) = distmax;
    else
        for j = 1:length(xx)
            dist(j) = sqrt(((xx(j) - maxs(i+1))^2+(yy(j) -
pk(maxs(i+1)))^2);
        end
        [distmax,xdistmax] = min(dist);
        dmax(i) = distmax;
    end
end

for i = 1:min([length(dmax) length(dmin)])
    R(i) = dmax(i)/dmin(i);
    if R(i) > 1;
        R(i) = 1/R(i);
    end
end
if mean(R) > 0.5;
    oscila = 1;
end

```

```

else
    oscila = 0;
end

```

### 7.3 Índice de Thornhill (2003)

```

function oscila = covariancia(y)
y = y - mean(y); %%remoção da média

acf=xcov(y, 'coeff');
acf = acf(round(length(acf)/2):end);
a = diff(sign(acf));
% cruzamentos por zero
zeros = find(a~=0);
%ultimo cruzamento analisado,o método usa só do 2° ao 12° cruzamento
ult = min(length(zeros),12);
%intervalos entre os zeros
intervalo = diff(zeros(2:ult));
% período médio da oscilação e desvio padrão
Tp=2*mean(intervalo);
Sp = std(intervalo);
r=((1/3)*Tp/Sp);
if r>1;
    oscila = 1;
else
    oscila=0;
end

```

### 7.4 Índice de Srinivasan (2007)

```

function flag = emd(y)
p0 = 1;
razao = 1;
while razao > 0.2
    % Identifica máximos e mínimos
    dy = diff(y);
    p1 = 1;
    p2 = 1;
    mins = [];
    maxs = [];
    for i = 2:length(dy)
        if dy(i)*dy(i-1) < 0 && dy(i) > 0
            mins(p1) = i;
            p1 = p1 + 1;
        elseif dy(i)*dy(i-1) < 0 && dy(i) < 0
            maxs(p2) = i;
            p2 = p2 + 1;
        end
    end
end

% Computa a emd
if length(maxs)*length(mins) > 3
    ypredmax = pchip(maxs, y(maxs), 0:length(y)-1);
    ypredmin = pchip(mins, y(mins), 0:length(y)-1);

    r1 = (ypredmax+ypredmin)/2;
    c1 = y - r1;

    yf{p0} = c1;
    p0 = p0 + 1;
    razao = std(r1)/std(y);
end

```

```

        y = r1;
    else
        yf{p0} = y;
        razao = 0;
    end
end
for i = 1:length(yf)
    flags(i) = covariancia(yf{i});
end
flags;
flag = max(flags);

```

## 7.5 Índice de Srinivasan (2012)

```

function flag = emd2012(y)

p0 = 1;
razao = 1;
yinicial=y;
while razao > 0.2
    % Identifica máximos e mínimos
    dy = diff(y);

    p1 = 1;
    p2 = 1;
    mins = [];
    maxs = [];
    for i = 2:length(dy)
        if dy(i)*dy(i-1) < 0 && dy(i) > 0
            mins(p1) = i;
            p1 = p1 + 1;
        elseif dy(i)*dy(i-1) < 0 && dy(i) < 0
            maxs(p2) = i;
            p2 = p2 + 1;
        end
    end

    % Computa a emd
    if length(maxs)*length(mins) > 3
        ypredmax = pchip(maxs,y(maxs),0:length(y)-1);
        ypredmin = pchip(mins,y(mins),0:length(y)-1);

        r1 = (ypredmax+ypredmin)/2;
        c1 = y - r1;

        yf{p0} = c1;
        p0 = p0 + 1;
        razao = std(r1)/std(y);
        y = r1;
    else
        yf{p0} = y;
        razao = 0;
    end
end

for i = 1:length(yf)
    A=cov(yf{i},yinicial);
    m(i)=A(1,2)/sqrt(var(yinicial)*var(yf{i}));
end
maxm=max(m);

```

```

for i = 1:length(m)
    lambda(i)=m(i)/maxm;
end

k=1;
for i = 1:length(yf)
    FT=fft(yf{i});
    X{k}=abs(FT);
    k=k+1;
end

for kk = 1:length(X)
    for i=1:length(X{kk})
        N=length(X{kk});
        S(kk)=(sqrt(N)-
((cumsum(abs(X{kk}(i))))/(sqrt(cumsum(abs((X{kk}(i))^2)))))))/(sqrt(N)-1);
    end
end

for i = 1:length(yf)
    flags(i) = covariancia(yf{i});
end

for j=1:length(yf)
    if flags(j)>0 && lambda(j)>0.5 && S(j)>0.5
        osc(j)=1;
    else
        osc(j)=0;
    end
end
if max(osc)>0
    flag=1;
else
    flag=0;
end

```

## 7.6 Índice de Li (2010)

```

function flag = dctoscila(y)
low = 1;
up = 3;
x=y;
% transforma por dct
y = dct(x-mean(x));
% corta os valores abaixo de 3 desv pad
SL = find(abs(y) < low*std(y));
yl = y;
yl(SL) = 0;
SL = find(abs(y) < up*std(y));
yu = y;
yu(SL) = 0;
%plot(y)

% se todos forem nulos, não oscila
flag = 0;
if sum(abs(yu)) ~= 0
    % acha os segmentos o original
    ynz = find(yu);
    dy = find(diff(ynz) - 1);

    if length(dy) < 3
        flag = 1;
    else

```



