

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

**DIAGNÓSTICO DE FALHAS EM PROCESSOS INDUSTRIAIS VIA  
CAUSALIDADE DE GRANGER**

DISSERTAÇÃO DE MESTRADO

GERCILIO CARLOS ZUQUI JUNIOR

VITÓRIA  
2015



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

**DIAGNÓSTICO DE FALHAS EM PROCESSOS INDUSTRIAIS VIA  
CAUSALIDADE DE GRANGER**

GERCILIO CARLOS ZUQUI JUNIOR

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

**Orientador:**

Prof. Dr. Celso Jose Munaro.

VITÓRIA  
2015



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

A comissão examinadora, abaixo assinada, aprova a dissertação, elaborada por Gercílio Carlos Zuqui Junior, como requisito parcial para obtenção de Grau de Mestre em Engenharia Elétrica.

Comissão examinadora:



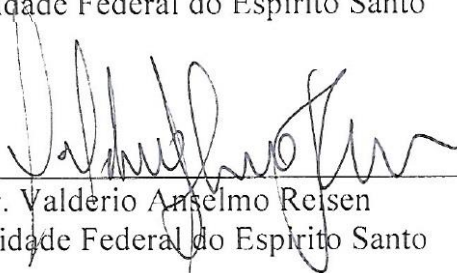
---

Prof. Dr. Celso Jose Munaro  
Universidade Federal do Espirito Santo



---

Prof. Dr. Thomas W. Rauber  
Universidade Federal do Espirito Santo



---

Prof. Dr. Valderio Anselmo Reisen  
Universidade Federal do Espirito Santo



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

---

Z95d Zuqui Junior, Gercilio Carlos, 1982-  
Diagnóstico de falhas em processos industriais via  
causalidade de Granger / Gercilio Carlos Zuqui Junior. – 2015.  
62 f. : il.

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

1. Detecção de sinais – Análise. 2. Localização de falhas  
(Engenharia). 3. Causalidade. 4. Processos de fabricação –  
Estudo de casos. 5. Análise de componentes principais.  
6. Estatística. I. Munaro, Celso Jose. II. Universidade Federal do  
Espírito Santo. Centro Tecnológico. III. Título.

CDU: 621.3

---





## Agradecimentos

A minha esposa, pela compreensão, nos meus momentos de ausência, e apoio nos momentos de dificuldade. A minha família, em especial as minhas irmãs, pelo incentivo incondicional e constante. Aos meus pais, pela educação que recebi que me tornou a pessoa que sou hoje, sem eles nada disso seria possível. Ao meu filho e aos meus amigos, por me propiciarem as horas necessárias de lazer para o descanso da mente.

Agradeço ao meu amigo, orientador e professor Celso José Munaro, pelos ensinamentos, paciência, apoio e incentivo, além de todo o tempo dedicado ao meu crescimento.

Agradeço também aos meus colegas da Vale, pela oportunidade, incentivo, ajuda e compreensão durante esses últimos anos.

Muito obrigado!



## Resumo

Falhas que se propagam por plantas industriais podem levar muitas malhas de controle a operar fora de faixas de segurança e de maiores ganhos econômicos. Neste contexto o diagnóstico de falhas em ambientes industriais é de fundamental importância para a competitividade de uma empresa. Neste trabalho é apresentado um estudo na área de detecção, identificação e diagnóstico de falhas. Uma revisão bibliográfica é realizada nas técnicas existentes e um método para indicar a fonte de falhas diretamente a partir de dados de operação é apresentado. As malhas de controle afetadas pela falha são identificadas baseando-se na análise por cartas de controle, componentes principais e estatística  $T^2$  de Hotelling e, as relações de causalidade entre as mesmas é detectada via causalidade de Granger. A metodologia foi aplicada em dois estudos de caso: uma central termelétrica muito sujeita a distúrbios devido à troca dos combustíveis usados para gerar energia; e em um forno de pelletização, que possui um grande nível de interação entre malhas de controle devido ao reaproveitamento de energia. O algoritmo proposto indicou corretamente as fontes das falhas propagadas pelas malhas de controle.



## Abstract

Faults that propagate in industrial plants can cause many control loops to operate outside of regions of security and greater economic profits. In this context, fault diagnosis in industrial plants is an essential feature for the company's competitiveness. In this paper, a study in the area of fault detection, identification and diagnosis is presented. A bibliographic revision is performed about the existing techniques and a method to indicate the source of faults directly from operating data is presented. The control loops affected by the disturbance are identified based on control charts, principal component analysis and Hotelling's  $T^2$  statistic and the causal relationships between them are detected via Granger causality. The methodology was applied to two case studies: a thermoelectric power plant subject to disturbances due to switching fuels used to generate energy; and a pelletizing furnace, that has a many control loops interactions caused by energy reuse. The proposed algorithm correctly indicated the sources of faults that propagated through the control loops.



## Lista de figuras

FIGURA 1 – FLUXOGRAMA PARA MONITORAMENTO DE PROCESSOS (CHIANG, RUSSELL E BRAATZ, 2002).....	23
FIGURA 2 - CLASSIFICAÇÃO DE MÉTODOS BASEADOS EM DADOS HISTÓRICOS DE PROCESSO (VENKATASUBRAMANIAN, RENGASWAMY, ET AL., 2003) .....	26
FIGURA 3 – SUPERIOR: HISTOGRAMA DOS DADOS E APROXIMAÇÃO DA FUNÇÃO DENSIDADE DE PROBABILIDADE; CENTRAL: LIMITES DE CONTROLE E SINAL NO TEMPO SEM FILTRO; INFERIOR: LIMITES DE CONTROLE E SINAL NO TEMPO FILTRADOS .....	28
FIGURA 4 – CONTROLE DE QUALIDADE DE DUAS VARIÁVEIS – COMPARAÇÃO ENTRE O CONTROLE UNIVARIADO COM O MULTIVARIADO .....	30
FIGURA 5- SINAIS $x_1, x_2$ e $x_3$ NO TEMPO .....	41
FIGURA 6 -ESTATÍSTICA $T^2$ PARA OS SINAIS $x_1, x_2$ e $x_3$ NO TEMPO .....	42
FIGURA 7 –CONTRIBUIÇÕES DOS SINAIS $x_1, x_2$ e $x_3$ PARA A VIOLAÇÃO DO LIMIAR .....	43
FIGURA 8 – ANÁLISE UNIVARIADA DOS SINAIS $x_1, x_2$ e $x_3$ .....	43
FIGURA 9- SINAIS $x_1, x_2$ e $x_3$ NO TEMPO, COM $x_1$ E $x_2$ CORRELACIONADOS .....	44
FIGURA 10 –ESTATÍSTICA $T^2$ PARA OS SINAIS $x_1, x_2$ e $x_3$ NO TEMPO, COM $x_1$ E $x_2$ CORRELACIONADOS .....	45
FIGURA 11 –CONTRIBUIÇÕES PARA A VIOLAÇÃO DOS SINAIS $x_1, x_2$ e $x_3$ , COM $x_1$ E $x_2$ CORRELACIONADOS .....	46
FIGURA 12 –ANÁLISE UNIVARIADA DOS SINAIS $x_1, x_2$ e $x_3$ , COM $x_1$ E $x_2$ CORRELACIONADOS.....	46
FIGURA 13 – ESQUEMÁTICO DE UMA CENTRAL TERMELÉTRICA.....	49
FIGURA 14 – DOZE MALHAS DE CONTROLE REPRESENTATIVAS DA TERMELÉTRICA NO TEMPO EM TORNO DO PONTO DE FALHA .....	50
FIGURA 15 – TESTES ESTATÍSTICOS $T^2$ E $Q$ DA CENTRAL TERMELÉTRICA .....	51
FIGURA 16 – CONTRIBUIÇÃO PERCENTUAL DE CADA SINAL PARA A VIOLAÇÃO DO LIMITE DA CENTRAL TERMELÉTRICA (CÍRCULO AZUL CHEIO - SELECIONADO / CÍRCULO AZUL VAZIO – NÃO SELECIONADO).....	51
FIGURA 17 – RESULTADO DOS TESTES UNIVARIADO DA CENTRAL TERMELÉTRICA (VERMELHO – SELECIONADO / AZUL – NÃO SELECIONADO) ...	52
FIGURA 18 – GRÁFICO DE TENDÊNCIA DOS SINAIS EM TORNO DO PONTO DE FALHA DA CENTRAL TERMELÉTRICA .....	53
FIGURA 19 – ESQUEMÁTICO DE UM FORNO DE PELOTIZAÇÃO (OUTOTEC, 2015) .....	54
FIGURA 20 – DOZE SINAIS REPRESENTATIVOS DO FORNO DE PELOTIZAÇÃO NO TEMPO EM TORNO DO PONTO DE FALHA .....	55
FIGURA 21 – TESTES ESTATÍSTICOS $T^2$ E $Q$ DO FORNO DE PELOTIZAÇÃO .....	56
FIGURA 22 – CONTRIBUIÇÃO PERCENTUAL DE CADA SINAL PARA A VIOLAÇÃO DO LIMITE DO FORNO DE PELOTIZAÇÃO (CÍRCULO AZUL CHEIO - SELECIONADO / CÍRCULO AZUL VAZIO – NÃO SELECIONADO).....	56
FIGURA 23 – RESULTADO DO TESTE UNIVARIADO DO FORNO DE PELOTIZAÇÃO (VERMELHO – SELECIONADO) .....	57
FIGURA 24 – GRAFO DIRECIONADO DA MATRIZ DE CAUSALIDADE DO FORNO DE PELOTIZAÇÃO.....	58
FIGURA 25 – GRÁFICO DE TENDÊNCIA DOS SINAIS EM TORNO DO INSTANTE DE FALHA DO FORNO DE PELOTIZAÇÃO .....	59





## Lista de Tabelas

TABELA 1 – SOFTWARES PARA MONITORAMENTO DESEMPENHOS EM MALHAS DE CONTROLE .....	38
TABELA 2 – MALHAS DE CONTROLE DA CENTRAL TERMELÉTRICA .....	52
TABELA 3 – MATRIZ DE CAUSALIDADE DE GRANGER DAS MALHAS SELECIONADAS DA CENTRAL TERMELÉTRICA .....	53
TABELA 4 – SINAIS DO FORNO DE PELOTIZAÇÃO.....	58
TABELA 5 – MATRIZ DE CAUSALIDADE DE GRANGER DOS SINAIS SELECIONADOS DO FORNO DE PELOTIZAÇÃO .....	58



## Glossário

PCA	<i>Principal component analysis</i>
ICAs	<i>Independent component analysis</i>
PLS	<i>Partial least squares</i>
IAE	<i>Integral of the absolute error</i>
ACF	<i>Autocorrelation Function</i>
Racf	Índice de taxa de decaimento da ACF
ODC	Caracterização e detecção de oscilação
PSD	<i>Power spectral density</i>
CEP	Controle estatístico de processo
QTA	<i>Qualitative trend analysis</i>
CTE	Central Termelétrica
EWMA	<i>Exponential weighted moving average</i>
COG	<i>Coke oven gas</i>
BFG	<i>Blast furnace gas</i>
KPIs	<i>Key performance indicator</i>
SPE	<i>Square prediction error</i>
PV	<i>Process variable</i>
SP	<i>Setpoint</i>
MV	<i>Manipulated variable</i>



## Sumário

Capítulo 1: Introdução .....	22
Capítulo 2: Revisão bibliográfica .....	26
2.1 Métodos de detecção de falhas baseados em dados históricos .....	26
2.1.1 Análise univariada.....	27
2.1.2 Análise multivariada .....	28
2.1.3 Análise por componentes principais (PCA).....	30
2.1.4 Detecção de falhas .....	32
2.2 Identificação de falhas .....	33
2.3 Diagnóstico de falhas .....	34
Capítulo 3: Metodologia proposta.....	39
3.1 Obtenção do modelo PCA.....	39
3.2 Detecção da Falha .....	40
3.3 Identificação da falha .....	40
3.4 Análise univariada.....	40
3.5 Diagnóstico da falha e busca pelas fontes.....	47
Capítulo 4: Estudos de caso .....	49
4.1 Central Termelétrica.....	49
4.2 Forno de pelotização .....	54
Capítulo 5: Conclusão.....	61

## Capítulo 1: Introdução

Métodos de projeção multivariados têm sido utilizados para analisar informações contidas em bases de dados históricas da indústria, com o objetivo de melhorar o desempenho e a qualidade do processo produtivo. A melhora na operação de um processo envolve o aprimoramento de métodos para análise de dados históricos, solução de problemas, monitoramento de processos, otimização de processos e produtos, detecção, isolamento e diagnóstico de falhas (Kourti, 2002).

Tradicionalmente, esses problemas são abordados com a construção de grandes modelos de processo e, através do uso desses modelos, é realizada a otimização do processo ou o diagnóstico de falhas. Entretanto, construir ou customizar um modelo para uma planta requer tempo e um considerável esforço, o que é difícil de justificar na indústria. Mais adiante, o modelo teórico somente prove as interações entre sinais para a etapa do processo que se está mais familiarizado. Vários parâmetros desse modelo encontram-se com valores fixados, baseados na literatura ou estimados a partir de dados históricos da planta. O sucesso desta abordagem através de modelamento é, geralmente, crucial para aplicações de otimização de processo, uma vez que deve ser lembrado que se otimiza o modelo e não o processo.

Entretanto, mesmo com os avanços obtidos nas áreas de otimização, controle distribuído e controle preditivo, a tarefa de responder a eventos anormais, ou falhas, ainda permanece manual, executado por um operador humano. Isso envolve a detecção temporal de uma falha, diagnóstico de suas fontes e tomada das devidas ações para trazer o processo novamente ao estado de operação normal e seguro. Esse conjunto de atividades deve ser chamado de gerenciamento de falhas, uma ferramenta fundamental para o controle supervisório.

O aumento no número de trabalhos publicados na área de detecção, isolamento e diagnóstico de falha, mostra um crescente interesse nesse assunto no ambiente científico e industrial. No trabalho de Isermann e Ballé (1997) um resumo da terminologia nesta área é feito, baseado no trabalho realizado pelo comitê técnico do IFAC SAFEPROCESS, sendo a terminologia seguida neste trabalho. Primeiramente diferencia-se os conceitos relacionados a análise de sinais:

- Falha: um desvio não permitido de pelo menos uma propriedade característica ou parâmetro de um sistema do comportamento aceitável, usual ou padrão.
- Distúrbio: uma entrada com efeito desconhecido e não controlado atuando no sistema;
- Perturbação: uma entrada agindo no sistema que resulta em um desvio temporário do estado atual.

Seguindo com a terminologia a ser utilizada para funções ligadas a análise de sinais:

- Detecção de falhas: determinação das falhas presentes em um sistema e o instante de tempo da ocorrência;
- Isolação de falhas: determinação do tipo, local e instante de tempo da falha detectada. Continuação da detecção de falhas;
- Identificação de falhas: determinação do tamanho e comportamento variante no tempo da falha. Continuação da isolamento de falhas;
- Diagnóstico de falhas: determinação do tipo, tamanho, localização e instante de tempo de uma falha detectada. Continuação da detecção de falhas, incluindo isolamento e identificação;
- Monitoramento: uma função continua e em tempo real para determinação das condições de um processo físico, através do armazenamento de informações, identificando anomalias no comportamento;

- Supervisão: monitoramento de um processo, tomando as devidas ações para manter a operação no caso de falha;
- Proteção: significa a supressão de um possível dano a uma planta ou equipamento.

As quatro funções associadas com monitoramento de processo são: detecção, isolamento e diagnóstico de falhas, bem como, a recuperação das condições normais do processo. Quando uma falha for detectada estas funções devem ser executadas conforme o fluxograma apresentado na Figura 1.




Figura 1 – Fluxograma para monitoramento de processos (Chiang, Russell e Braatz, 2002)

Falhas geralmente se propagam para as malhas de controle subsequentes podendo até mesmo vir a desestabilizar uma planta. Dentre as possíveis causas de falhas e baixo desempenho em malhas de controle, destacam-se (Campos, 2011):

- Projeto inadequado de transmissores e atuadores, fazendo com que o controle opere fora da faixa ideal;
- Mau funcionamento de instrumentos, como: transmissores defeituosos, tomadas obstruídas, falta de calibração, entre outros;
- Mau funcionamento em válvulas de controle: agarramento, falta de calibração, operação fora da faixa linear, entre outros;
- Mau funcionamento em atuadores: folga, saturação, etc.;
- Sintonia inadequada de controladores;
- Estratégia de controle inadequada;
- Mudanças de pontos de operação: variações nos insumos, combustíveis, níveis de produção, entre outros.

A análise de sinais é uma importante ferramenta para o monitoramento de desempenho, detecção e diagnóstico de falhas em processos industriais. Os sinais comumente utilizados são instrumentos de proteção e processo, e os sinais de malhas de controle. Uma malha de controle é composta, basicamente, por três sinais: variável de processo (PV) – sinal que se deseja controlar; *setpoint* (SP) – referência do operador para a variável de processo; e variável controlada (MV) – sinal que é utilizado para o controle do atuador. A variável de processo é o sinal da malha de controle utilizado nesta dissertação. Será assumindo distribuição normal para todos os sinais utilizados neste trabalho, tanto para os simulados quanto para os dados provenientes da indústria.

Usualmente as falhas investigadas são oscilações, assunto amplamente difundido na literatura com uma gama de algoritmos para identificar a presença e a frequência portadora. O uso de análise por componentes principais (PCA – *Principal component analysis*) foi proposto por Thornhill, Shah, *et al.*, (2002) para identificação de espectros semelhantes, assim como, a análise por componentes independentes (ICA – *Independent component analysis*) foi utilizada por Xia, Howell e Thornhill (2005) para detectar oscilações. Já em Hägglund (1995), o cálculo do IAE (*integral of the absolute error*) entre sucessivos cruzamentos por zeros foi empregado como método de detecção de oscilação em tempo real, abordagem semelhante a utilizada por Forsman e Stattin (1998). Em Thornhill e Hägglund (1997), foi utilizado o conceito de fator de regularidade para a mesma aplicação.

Ferramentas estatísticas como função de autocorrelação do sinal (ACF), tem sido largamente empregada para detecção de oscilações, uma vez que a análise temporal está sujeita a presença de ruídos que podem dificultar a aplicação dos métodos baseados em tempo (Depizzol, 2011). A ACF é capaz de atenuar o efeito do ruído preservando a frequência original dos sinais no tempo. Em Miao e Seborg (1999) foi proposto um índice de taxa de decaimento da ACF (Racf), a partir da relação entre o decaimento da ACF e o amortecimento de um sinal senoidal de segunda ordem. Através desta comparação um limiar de decaimento (Racf) foi determinado, permitindo sua utilização na detecção do comportamento oscilatório de malhas de controle. Em Karra e Karim (2009), foi proposto o método ODC (caracterização e detecção de oscilação), baseado no algoritmo proposto em Thornhill, Shah, *et al.* (2002). Esse método propõe melhorias utilizando a PSD (*power spectral density*) na identificação e separação de prováveis frequências de oscilação.

O tratamento de falhas não associadas a oscilações é também de fundamental importância para o bom desempenho do processo, por geralmente se propagarem pelas malhas de controle da planta afastando-as de seu valor de referência. Ao contrário das oscilações, sua detecção e indicação da fonte pode ser mais problemática uma vez que em grande parte dos casos possui uma característica transitória. O procedimento convencional é a análise temporal, buscando na base de dados da planta as malhas afetadas pela falha, e a investigação da causa através do conhecimento do processo. Esse método pode ser extremamente trabalhoso uma vez que o número de variáveis envolvidas geralmente é grande, o que pode levar a análise e resultados não conclusivos devido à complexidade da inter-relação entre as malhas de controle.

Desta forma, faz-se necessário a definição de métodos capazes de capturar o funcionamento normal de um processo, de forma a identificar quando algo fora do normal possa estar influenciando o comportamento da planta. A utilização de cartas de controle tem sido amplamente empregada na indústria para acompanhamento do desempenho e detecção de falhas em uma malha de controle, por ser uma abordagem estatística simples e eficaz em grande parte dos casos. Abordagens como a análise por componentes principais e mínimos quadrados parciais (PLS - *partial least squares*) combinadas com o uso de cartas de controle multivariadas são importantes métodos estatísticos para detecção e isolamento de falhas em sistemas multivariados, utilizando o princípio da obtenção de modelos de comportamento do conjunto de sinais envolvidos e não somente comportamento individual de um sinal. Outra abordagem multivariada é a utilização de redes neurais para classificação e aproximação funcional de sistemas, onde são construídos modelos para a predição do comportamento de algumas variáveis de saída, através da modelagem de um conjunto de variáveis de entrada.

Após o isolamento das malhas de controle afetadas pela falha, a identificação das possíveis fontes faz-se necessária, uma vez que esse grupo selecionado pode conter um grande número de malhas de controle cuja relação de causalidade não é trivial. Em Thornhill, Cox e Paulonis (2003) foi proposto um índice não linear combinado com o conhecimento do processo para identificação da causa raiz devido a atrito em válvulas de controle. Em Xia, Howell e Thornhill (2005) é proposto o uso de um espectro ICA de multi-resolução para detectar e isolar a fonte de múltiplas oscilações, um índice de significância é utilizado para indicar a fonte. O trabalho de Jiang, Patwardhan e Shah (2009) incorporou conhecimento de processo com teoria de grafos para ajudar na indicação da fonte.

Os métodos de inferência de causalidade têm sido amplamente utilizados para a indicação de fonte de falhas em processos industriais, uma vez que o conhecimento das relações de causalidade entre os sinais afetados pode indicar onde a falha se originou. Em Bauer e Thornhill (2008) e Stockmann, Haber e Schmitz (2012) a estimativa de tempo de atraso entre amostras foi utilizada para a indicação de fontes de falhas. A ideia da entropia de transferência é utilizada em Bauer, Cox, *et al.*, (2007) para propor um método baseado em dados de processo para determinar a direção da propagação de uma falha. Já em Yuan e Qin (2014) o método da causalidade de Granger no domínio do tempo e da frequência é aplicado para diagnosticar fontes e caminhos de propagação da oscilação,



determinando as relações de causalidade entre dois sinais através da comparação do erro de predição de uma malha com e sem a inclusão da outra malha no cálculo do modelo auto-regressivo.

Mesmo com a gama de trabalhos supracitados, um método completo, capaz de tratar o problema desde a detecção da falha até seu diagnóstico, faz-se necessário. Um procedimento com este objetivo é proposto neste trabalho, tratando os três primeiros quadros da Figura 1, ficando somente a definição de ações para recuperação do processo a cargo da equipe de operação e manutenção.

Esta dissertação está organizada da seguinte forma: no capítulo 2 é feita uma revisão da bibliografia, apresentando as técnicas utilizadas neste trabalho. O capítulo 3 apresenta a metodologia proposta. No capítulo 4 a metodologia proposta é aplicada em dois estudos de caso reais da indústria, em uma planta termelétrica e em um forno de pelletização. O capítulo 5 traz as conclusões finais e sugestões de trabalhos futuros.

## Capítulo 2: Revisão bibliográfica

Neste capítulo serão apresentados os conceitos e as ferramentas utilizados ao longo do presente trabalho. Na secção 2. 1 os métodos para detecção de falhas em processos industriais são discutidos. As análises estatísticas univariadas e multivariadas, baseadas em CEP (controle estatístico de processo) e análise por componentes principais, aqui utilizadas, são detalhadas nas secções 2.1.1 a 2.1.4 . Na secção 2. 2 é apresentado o método para a identificação de falhas através do modelo PCA dos dados. Enquanto que na secção 2. 3 são discutidos os métodos para determinação das relações de causalidade, no intuito de isolar as variáveis que podem ser indicadas como fonte.

### 2. 1 Métodos de detecção de falhas baseados em dados históricos

Em contraste com métodos baseados em modelos de processo que precisam de um certo conhecimento da planta *a priori*, métodos baseados em dados de processo somente necessitam de dados históricos para detecção de comportamentos anormais de uma planta (Venkatasubramanian, Rengaswamy, *et al.*, 2003), podendo ser divididos em dois grupos: qualitativos e quantitativos. Os dois principais métodos qualitativos são os sistemas especialistas e os de modelagem de tendências. Já os métodos quantitativos podem ser classificados como métodos não estatísticos ou estatísticos. Redes neurais são uma importante classe de métodos não estatísticos. As técnicas de análise por componentes principais (PCA), mínimos quadrados parciais (PLS) e classificação por padrões de comportamento estatístico combinadas com cartas de controle multivariadas, compõem os principais métodos estatísticos para detecção de falhas. A classificação dos diferentes métodos que extraem conhecimento de dados históricos de processo é apresentada na Figura 2.

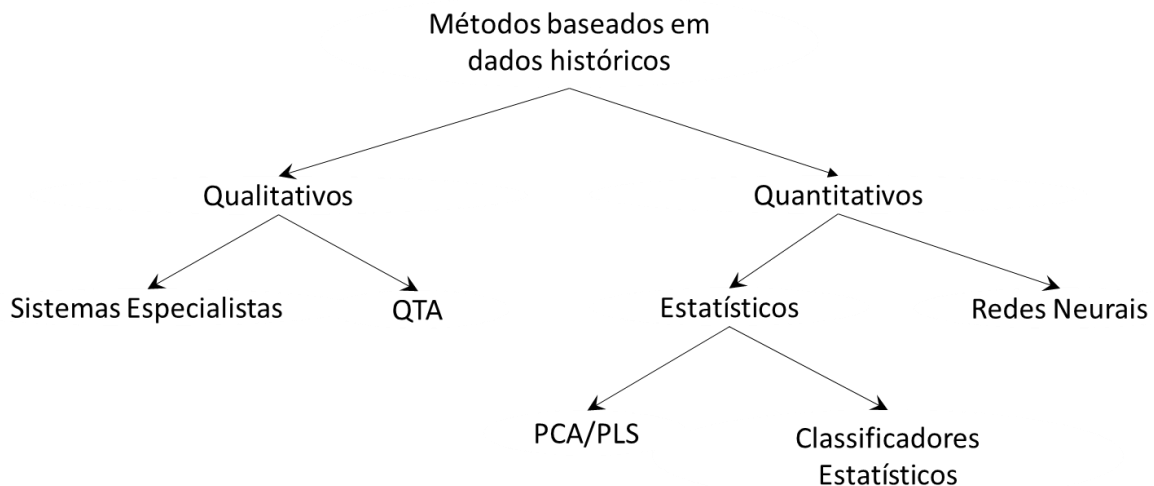


Figura 2 - Classificação de métodos baseados em dados históricos de processo (Venkatasubramanian, Rengaswamy, *et al.*, 2003)

Um sistema especialista é um método qualitativo de detecção de falhas, podendo ser definido por um sistema altamente especializado que soluciona problemas em um estreito horizonte de conhecimento. Outro método é a análise qualitativa de gráficos de tendência (QTA – *qualitative trend analysis*), que modela o comportamento da tendência temporal dos sinais. O QTA pode ser utilizado para explicar a ocorrência de eventos importantes no processo, além de ser capaz de prever futuros estados.

Os métodos quantitativos essencialmente transformam o problema de detecção de falhas em um problema de reconhecimento de padrões. O objetivo do reconhecimento de padrões é, geralmente, a classificação dos dados em classes pré-determinadas. Métodos estatísticos utilizam o conhecimento de distribuições já conhecidas para realizar esta classificação. A combinação do método PCA, que é capaz de extrair as principais tendências dos dados, com a estatística  $T^2$  de Hotelling representa um

importante método quantitativo para detecção de falhas.

Um interesse considerável pode ser percebido na utilização de redes neurais para o problema de detecção de falhas na literatura, que representa outro importante método quantitativo. Redes neurais foram propostas para a classificação e aproximação funcional de problemas, através da parametrização do classificador. De maneira geral, redes neurais utilizadas para diagnóstico de falhas podem ser classificadas por duas dimensões: (i) a arquitetura da rede como sendo uma camada de neurônios, múltiplas camadas de neurônios e assim por diante; e (ii) a estratégia de aprendizado sendo supervisionada ou não.

### 2.1.1 Análise univariada

O controle de qualidade representa uma das mais antigas tentativas de utilização da estatística no monitoramento de processo e detecção de falhas *online*. As cartas de controle foram introduzidas em Shewhart (1931), seguidas por outros métodos como o gráfico de somas cumulativas (Page, 1954). A abordagem por cartas de controle baseia-se na suposição que o processo, sujeito somente a sua variabilidade natural (*common cause variation*), permanecerá em controle estatístico enquanto algumas variáveis de processo e de qualidade permanecem próximas de seus valores desejados (Venkatasubramanian, Rengaswamy, *et al.*, 2003).

Admitindo-se um processo estável e invariante no tempo, é possível estabelecer um modelo para seu comportamento através da análise do sistema em condições normais de operação, possibilitando assim a predição de seu desempenho (Howard, 2003). A detecção de mudanças de comportamento da planta torna-se possível através do monitoramento *online* das variáveis de processo, comparando seu comportamento com padrões normais já estabelecidos (Campos, 2011).

Um processo, mesmo que esteja em condições de operação normais, ainda apresenta uma certa variabilidade que lhe é característica. Esta variabilidade muitas vezes é atribuída ao ruído, idealizado como um sinal aleatório com espectro de frequência contínuo e distribuição gaussiana. Desta forma pode-se dizer que um sinal se encontra em controle estatístico se sua variabilidade for atribuída unicamente ao ruído e seus valores estejam dentro dos limites de controle estabelecidos (Campos, 2011).

Shewhart percebeu que em alguns momentos tomamos ações quando não eram necessárias, bem como, deixamos o processo sem ação quando na verdade uma ação era necessária no primeiro sinal de problema. Isto motivou a criação de uma regra que fosse ao mesmo tempo, sensível suficiente para identificar um caso especial, mas não tão sensível para não tomar ações em situações normais de operação, estando assim, centrada na escolha dos limites que determinarão se uma variável se encontra em controle estatístico. Shewhart escolheu limites que estivessem aproximadamente 2 desvios padrão da média da amostra, que corresponde a um nível de significância de 95%, também conhecidos como limites de controle superiores (LSC) e inferiores (LIC). Uma violação a esses limites representa uma grande alteração no comportamento do sinal, podendo servir, de forma confiável, como um alarme da ocorrência de uma falha.

Um conjunto de 10.000 amostras de um sinal aleatório, gaussiano, de média zero e desvio padrão unitário foi gerado de forma a ilustrar a utilização de cartas de controle. A partir da amostra 9.900 uma tendência em rampa crescente é adicionada no sinal simulando uma mudança de comportamento. O gráfico superior da Figura 3 mostra o histograma do sinal e a aproximação da função de densidade de probabilidade a partir do mesmo. No gráfico central é apresentado o comportamento do sinal do tempo a partir da amostra 9.600. Analisando o comportamento do sinal pode-se perceber que várias amostras violaram os limites de controle inferior e superior, mesmo com a mudança de comportamento iniciando-se somente a partir da amostra 9.900. Isto deve-se a presença

do ruído, que pode aumentar muito a incidência de falsos alarmes, o que é totalmente indesejável para sistemas de detecção de falhas. De forma a mitigar este problema, um filtro EWMA (*exponential weighted moving average*) pode ser implementado através da equação (Kourti e Macgregor, 1995)

$$y_{f_t} = \alpha y_t + (1 - \alpha)y_{f_{t-1}} \quad (2.1)$$

onde  $y$  é o sinal a ser filtrado,  $y_f$  é o sinal filtrado e  $\alpha$  é o fator de ajuste ( $0 < \alpha \leq 1$ ). Este filtro reduz a incidência de falsos alarmes, conforme pode ser visto no gráfico inferior da Figura 3, com o prejuízo de introduzir atraso na detecção da falha, o que é aceitável para grande parte dos sinais monitorados na indústria.

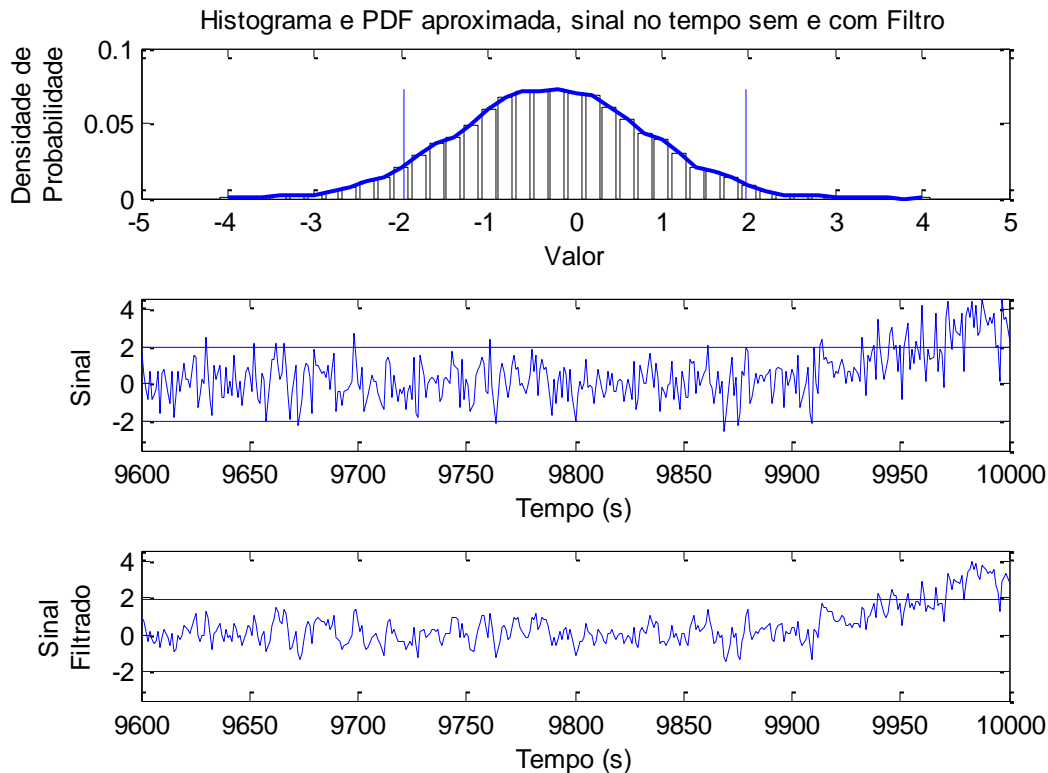


Figura 3 – Superior: histograma dos dados e aproximação da função densidade de probabilidade; Central: Limites de controle e sinal no tempo sem filtro; Inferior: Limites de controle e sinal no tempo filtrados

### 2.1.2 Análise multivariada

Os métodos tradicionais de controle estatístico de processo ignoram o fato de que com o aumento na capacidade de processamento dos sistemas de controle industriais, um grande volume de dados é coletado diariamente a cada poucos segundos para várias variáveis de processo ( $X$ ), como temperaturas, pressões, vazões, entre outros. Variáveis ligadas a qualidade final do produto ( $Y$ ), como octanagem da gasolina, percentual de carbono no aço, etc., estão disponíveis em uma taxa de amostragem muito mais baixa, geralmente vinculada a análises laboratoriais. Todas estas informações devem ser utilizadas para extrair informações que auxiliem no monitoramento e diagnóstico do desempenho de um sistema. Entretanto, estas variáveis não são independentes entre si. O exame de cada variável individualmente, como se elas fossem independentes, torna a interpretação e o diagnóstico extremamente difícil. Somente métodos multivariados que utilizam as informações de todas as variáveis simultaneamente, podem extrair a informação da direção de variações no processo, ou que significa como todas as variáveis se comportam em conjunto (Kourti e Macgregor, 1995).

Na maior parte das indústrias, abordagens univariadas como cartas de controle de Shewhart são utilizadas para monitorar separadamente as variáveis mais importantes para qualidade final do produto. A dificuldade nesta abordagem está no fato destas variáveis não serem independentes entre si, ou seja, nenhuma delas pode representar individualmente a qualidade do produto. A qualidade do produto só pode ser definida por um determinado conjunto de valores simultâneos de todas as variáveis, o que é uma propriedade multivariada (Kourti e Macgregor, 1995).

A dificuldade da utilização de carta de controle univariada pode ser ilustrada pelo experimento a seguir, que visa ilustrar que uma mudança na correlação entre dois sinais pode não ser percebido através da análise univariada. Supondo que dois sinais  $y_1$  e  $y_2$  representem a qualidade do produto final, gerados através das equações

$$y_{1t} = 0,5y_{1t-1} + 0,2y_{2t-1} + r_{1t} \quad (2.2)$$

$$y_{2t} = 0,1y_{2t-1} + a_{22}y_{1t-1} + 0,1r_{2t} \quad (2.3)$$

onde  $r_1$  e  $r_2$  são sinais aleatórios com distribuição normal de média zero e desvio padrão unitário. O valor do coeficiente  $a_{22}$  é  $-0,7$  e o número de amostras  $N$  é igual a 60. O primeiro e o segundo gráfico da Figura 4 ilustram a carta de controle dos sinais  $y_1$  e  $y_2$  no tempo, com os limites de controle sendo 3 desvios padrão para mais e para menos. O terceiro gráfico da mesma figura ilustra o comportamento conjunto  $y_1$  versus  $y_2$ , com a elipse representando o contorno para o estado em controle estatístico (pontos azuis). A partir da amostra 40 o parâmetro  $a_{22}$  é alterado para  $0,7$  positivo, simulando uma alteração na correlação dos sinais, que pode ser visualizada pelos pontos em vermelho do mesmo gráfico. Ao analisar as cartas de controle dos sinais não é possível perceber nenhuma mudança, uma vez que nenhum ultrapassou os limites de controle. Entretanto, ao analisar o comportamento conjunto dos sinais, pode-se observar que grande parte dos pontos após a mudança encontram-se fora a elipse, indicando uma mudança no comportamento dos mesmos. Portanto, através deste experimento é possível perceber que os métodos de monitoramento multivariados são capazes de detectar falhas que não são percebidas pelos univariados.

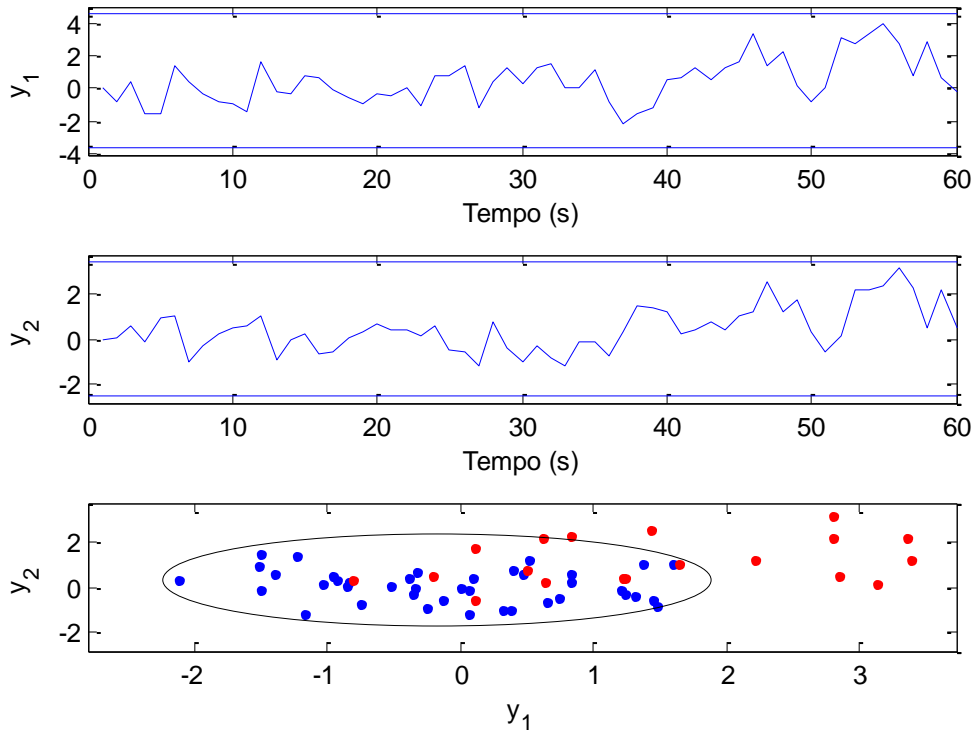


Figura 4 – Controle de qualidade de duas variáveis – comparação entre o controle univariado com o multivariado

Apesar das limitações dos métodos univariados, cartas de controle continuam como a principal forma de monitoramento de qualidade utilizada pela indústria (Kourti e Macgregor, 1995). Entretanto, vários métodos multivariados foram propostos na literatura para tratar desse problema, como mínimos quadrados parciais e análise por componentes principais combinado com a estatística  $T^2$  de Hotelling.

### 2.1.3 Análise por componentes principais (PCA)

A análise de componentes principais é uma técnica criada para reduzir a dimensão do espaço amostral transformando os sinais correlacionados em um novo conjunto de sinais não correlacionados (Villegas, Fuente e Rodríguez, 2010), mantendo a maior parte da variância original. Ela desacopla o espaço amostral  $x$  em um novo conjunto de variáveis não correlacionadas correspondendo aos elementos de  $y$ :

$$y = V^T x \quad (2.4)$$

onde  $y$  é um vetor coluna conhecido como *scores* e  $x$  é um vetor coluna de amostras, onde as tendências foram removidas e o desvio padrão foi normalizado. A matriz  $V$  é composta pelos autovetores obtidos através decomposição em valores singulares da matriz de covariância amostral  $S$  dos dados de treinamento (Bezergianni e Kalogianni, 2008)

$$S = \frac{1}{n-1} X^T X = V \Lambda V^{-1} \quad (2.5)$$

onde  $X$  é a matriz de amostras com várias realizações de  $x$  e, de acordo com Chiang, Russell e Braatz (2002), a diagonal da matriz diagonal  $\Lambda \in R^{m \times m}$  contém os autovalores da matriz  $S$ , reais e positivos, em ordem decrescente de magnitude ao longo de sua diagonal ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ). A variância explicada pelo autovetor correspondente a  $i$ -ésima coluna de  $V$  é igual a  $\lambda_i$ , o que significa que  $\lambda_i =$

$\sigma_i^2$  (Villegas, Fuente e Rodríguez, 2010), onde  $\sigma_i$  é o desvio padrão explicado pelo vetor correspondente a  $i$ -ésima coluna de  $V$ .

Os dados de treinamentos correspondem ao espaço amostral onde considera-se que as variáveis estão operando normalmente, ou seja, sem a presença de uma falha. A correta escolha dos dados de treinamento é uma importante etapa do método, uma vez que eles reproduzem a variabilidade natural dos dados, que pode ser considerada como normal, o que evita a geração de falsos alarmes. O tratamento prévio dos dados para a aplicação do método, como a retirada de médias temporais e a normalização pelo desvio padrão, é importante para evitar que tendências e diferenças de escalas possam interferir no computo das componentes principais.

A matriz  $P \in R^{m \times a}$  (*loading matrix*) é composta pelos  $a$  autovetores associados com os maiores autovalores da matriz de covariância amostral  $S$ , que explicam a variabilidade dos dados de treinamento, podendo também ser chamada de modelo PCA. As projeções do espaço amostral  $X$  em um espaço de menor dimensão estão contidas na matriz de *scores*  $T$  e a projeção reversa de  $T$  no espaço de observação está contida na matriz  $\hat{X}$ :

$$T = XP \quad (2.6)$$

$$\hat{X} = TP^T \quad (2.7)$$

Um passo importante do método está na escolha das componentes principais contidas na matriz  $P$ , podendo ser selecionadas por uma das quatro técnicas apresentadas em Chiang, Russell e Braatz (2002):

- Percentual da variância: determina o menor número de componentes principais necessários para explicar um percentual específico da variância total;
- *Scree test*: assume que a variância,  $\sigma_i^2$ , correspondente a um ruído branco possui um perfil linear. O número de autovetores selecionados  $a$ , é determinado localizando o valor de  $\sigma_i^2$  que não é mais linear. A identificação desse ponto pode ser ambígua, tornando difícil sua automatização;
- Análise paralela: determina a dimensão do espaço de *scores* comparando o perfil da variância com o de variáveis independentes. A redução da ordem é determinada pelo ponto onde o perfil das duas variâncias, matriz  $\Lambda$  e variáveis independentes, se cruzam. Esta técnica garante que correlações significantes foram capturadas no espaço de *scores*, sendo bem atrativa, uma vez que é simples de automatizar;
- Validação cruzada: utiliza o valor residual previsto para a soma dos quadrados

$$PRESS(i) = \frac{1}{mn} \|X - \hat{X}\|_F^2 \quad (2.8)$$

onde  $i$  é o número do autovetores mantidos para calcular  $\hat{X}$  e  $\|\cdot\|_F^2$  é a norma Frobenius. Para implantação do teste, os dados de treinamento devem ser divididos em grupos. A estatística *PRESS* é calculada para várias dimensões do espaço de *scores* ( $i$ ) em um grupo. Isso deve ser repetido para cada grupo, e o valor de  $i$  associado com a menor média da estatística *PRESS* determina a dimensão do espaço de *scores*.

O procedimento para obtenção do modelo PCA pode ser resumido nos seguintes passos:

- i. Organizar os dados em uma matriz de amostras  $X$  onde cada coluna corresponde a uma variável e cada linha a uma realização;
- ii. Normalizar as variáveis, subtraindo a média dividindo pelo o desvio padrão amostral de cada sinal;

- iii. Calcular a matriz de covariância amostral  $S$ ;
- iv. Reduzir a dimensão dos dados através da escolha dos autovalores que representam a variabilidade requerida dos dados, utilizando um dos critérios aprestandos acima.

#### 2.1.4 Detecção de falhas

A detecção de falhas pode ser realizada com o uso de PCA e da estatística de Hotelling ( $T^2$ ). O valor de  $T^2$  de menor dimensão pode ser calculado para cada nova amostra  $x$  através da equação (Chiang, Russell e Braatz, 2002):

$$T^2 = x^T P \Lambda_a^{-1} P^T x \quad (2.9)$$

onde  $a$  é o número de componentes principais selecionadas,  $x$  é um vetor com uma amostra,  $P$  é a matriz de componentes principais, e  $\Lambda_a$  é a matriz de autovalores da decomposição em valores singulares da matriz  $S$  reduzida a dimensão  $a$ . A métrica utilizada na carta de controle de Hotelling baseia-se na distância estatística entre uma amostra multivariada e o centro do modelo estatístico dos dados (Montgomery, 2009).

A distribuição  $F$  é utilizada para obter o limite superior do intervalo de confiança, sendo calculado por:

$$T^2_{a,\alpha,n} = \frac{a(n-1)}{n-a} F_{a,n-a,\alpha} \quad (2.10)$$

onde  $a$  é o número de componentes principais,  $n$  é o número amostras dos dados de treinamento, e  $\alpha$  é o nível de significância.

Este método pode ser interpretado como uma medida da variabilidade sistêmica do processo, sob condições normais de operação. Um valor de  $T^2$  que viole o limite estabelecido por  $T^2_{a,\alpha,n}$ , indica que o sistema está fora de controle estatístico, o que indica a presença de uma falha (Villegas, Fuente e Rodríguez, 2010).

A estatística  $T^2$  trata somente da porção do espaço amostral explicado pelas componentes principais. Entretanto, em alguns casos, as falhas afetam primeiramente o espaço residual, explicado pelos autovetores correspondentes aos menores autovalores. De forma a complementar a estatística  $T^2$ , a porção do espaço amostral correspondente aos menores autovalores pode ser monitorada através da estatística  $Q$ , também conhecida como SPE (*square prediction error*), que é dada por (Chiang, Russell e Braatz, 2002):

$$Q = r^T r \quad (2.11)$$

$$r = (I - PP^T)x \quad (2.12)$$

onde  $r$  é o vetor de resíduos, uma projeção do vetor de amostra  $x$  no espaço residual. A distribuição para a estatística  $Q$  foi aproximada por (Chiang, Russell e Braatz, 2002):

$$Q_\alpha = \theta_1 \left[ \frac{h_0 c_0 (2\theta_1)^{\frac{1}{2}}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{1/h_0} \quad (2.13)$$

onde  $\theta_i = \sum_{j=a+1}^m \sigma_j^{2i}$ ,  $h_0 = 1 - (2\theta_1\theta_3)/(3\theta_2^2)$ ,  $\alpha$  é o nível de significância e  $a$  representa o



número de componentes principais seleccionadas. Neste trabalho os dois testes estatísticos serão utilizados para identificação do momento da falha aumentando a robustez dos resultados, conforme recomendado em Chiang, Russell e Braatz (2002).

## 2.2 Identificação de falhas

Uma vez detectado o instante do início da falha, faz-se necessário a seleção das variáveis afetadas. Em Chiang, Russell e Braatz (2002) a contribuição de cada variável para a violação do limite é utilizada como critério de seleção. Um procedimento para o cálculo da contribuição de cada variável através da matriz de *scores*  $T$ , é proposto:

1. Conferir se os *scores* normalizados  $(t_i/\sigma_i)^2$  para a amostra  $x$  atendem a equação (2.14), determinando assim os  $r \leq a$  *scores* responsáveis pela violação. Os *scores* selecionados serão considerados como os principais contribuidores para a falha;

$$(t_i/\sigma_i)^2 > \frac{1}{\alpha} T^2_{a,\alpha,n} \quad (2.14)$$

2. Calcular a contribuição de cada variável  $j$  para o *score*  $i$  selecionado

$$c_{i,j} = \frac{t_i}{\sigma_i^2} P_{i,j} (x_j - E_{x_j}) \quad (2.15)$$

onde  $P_{i,j}$  é o elemento  $(i,j)$  da matriz de componentes principais e  $E_{x_j}$  é a média temporal de  $x$  no período de treinamento;

3. Fazer  $c_{i,j} = 0$  caso  $c_{i,j} < 0$ ;
4. Calcular a contribuição total da  $j$ -ésima variável  $x_j$

$$C_j = \sum_{i=1}^r c_{i,j} \quad (2.16)$$

5. Analisar a contribuição de todas as variáveis.

Portanto, as estatísticas  $T^2$  e  $Q$  serão os métodos utilizados neste trabalho para a detecção da falha e, a contribuição de cada variável para a violação, calculada através do procedimento acima, será utilizada como critério de seleção para agrupamento das variáveis afetadas pela falha.

Um limite para a variabilidade a ser explicada será definido, sendo o parâmetro para a seleção das componentes principais a manter, bem como, o nível de significância para os testes estatísticos. Após a seleção e agrupamento das variáveis afetadas pela falha, faz-se necessária a procura pela fonte da falha, uma vez que as variáveis seleccionadas representam aquelas com maiores contribuições para o aumento da variabilidade, e, o maior contribuidor não necessariamente é a causa da falha.

Finalmente, após todos estes testes, as variáveis relacionadas podem conter variáveis que foram afetadas por outras causas, como uma mudança de referência, por exemplo. Entretanto, o passo subsequente apresentado na próxima secção tratará esses casos, bem como da indicação da fonte.

## 2.3 Diagnóstico de falhas

Dado um conjunto de sinais afetados por uma falha, previamente selecionados através dos métodos apresentados anteriormente, faz-se necessário conhecer as relações de causalidade entre os sinais de forma a isolar a fonte. De acordo com Schindler e Verdes (2007), as condições para inferir causalidade são:

- i. Deve existir uma covariância concomitante entre dois sinais  $X$  e  $Y$ ;
- ii. Deve existir uma assimetria temporal ou ordenação no tempo entre as sequências de amostras dos sinais  $X$  e  $Y$ ;
- iii. A covariância entre  $X$  e  $Y$  não pode desaparecer quando o efeito de um terceiro sinal (e.x. um sinal que causa tanto  $X$  quanto  $Y$ ) é removido.

A forma mais comum e direta para conhecer as relações de causalidade entre sinais é utilizar a documentação sobre o processo (Thambirajah, Benabbas, *et al.*, 2009) e verificar a relação existente entre os sinais agrupados. A primeira dificuldade desse procedimento é a complexidade, pois pode requerer a análise da relação entre dezenas de sinais, exigindo um grande esforço e uma metodologia bem definida. A segunda dificuldade é que as relações entre os sinais mudam em função de alterações simples tais como colocar uma malha de controle em modo manual, o que é feito usualmente, por exemplo, para cessar oscilações quando a malha de controle está em modo automático. Além disto, a documentação das malhas de controle pode não estar atualizada com a situação atual da planta.

Outro método comumente utilizado para inferir causalidade é a correlação de sinais, que indica que os sinais testados estão estaticamente relacionados, no tempo ou na frequência, sendo a segunda imune a atrasos no tempo. *Softwares* de auditoria de malhas de controle, como *Expertune's PlantTriage* e *Process-Doctor*, calculam a matriz de correlação dos sinais, entretanto esta informação não dá a direção da interação (quem é causa e quem é o efeito), além de em alguns casos, não ser capaz de determinar a relação entre sinais, não servindo, portanto, para isolar a fonte.

Em Bauer e Thornhill (2008) é proposta uma abordagem prática e robusta que utiliza a função de correlação cruzada para estimar o tempo de atraso entre amostras, visando construir um modelo qualitativo do caminho de propagação na forma de um mapa causal. O trabalho apresentado em Stockmann, Haber e Schmitz (2012) também utiliza a estimação de tempo de atraso entre séries temporais para a identificação e propagação de falhas em plantas industriais. Devido ao fato que a estimativa de atrasos temporais em sistemas com múltiplas entradas e única saída (MISO) ou sistemas não lineares é um desafio com os métodos convencionais, um novo método baseado na entrada do  $k$  vizinho mais próximo (*k nearest neighbor*) foi desenvolvido e validado. De acordo com as condições para inferir causalidade apresentadas no início desta seção, o atraso no tempo pode ser utilizado para inferir causalidade (ii), entretanto é impossível determinar a presença de uma realimentação entre malhas de controle. A inferência de causalidade através de atrasos no tempo utiliza o sinal da subtração entre o atraso no tempo calculado de um sinal para o outro, e vice-versa, para determinar a direção da relação de causalidade, desprezando assim qualquer informação sobre a presença de uma realimentação.

Outra abordagem baseada em dados históricos é proposta em Yuan e Qin (2014) para diagnosticar as fontes e os caminhos de propagação de oscilações em plantas industriais. O método primeiramente utiliza o conceito de variáveis latentes para selecionar o conjunto de variáveis afetadas por uma oscilação, aplicando os métodos de causalidade Granger no domínio do tempo e da frequência para prover um diagnóstico das fontes e caminhos de propagação da oscilação. Em Zuqui e Munaro (2014) o método de causalidade de Granger é utilizado para a indicação de fontes no caso

da ocorrência de falhas em uma termelétrica.

O método da entropia de transferência (*transfer entropy*) foi proposto por Schreiber (2000) como a medida da transferência direta de informação entre dois processos, assimétrico no tempo. O método da entropia de transferência não está baseado na previsão de series temporais, mas sim, na redução da incerteza. Pode ser dito que a entropia de transferência de  $y$  para  $x$  é o grau com o qual os valores de  $y$  esclarecem o futuro de  $x$ , quando comparado como os valores de  $x$  esclarecem seu próprio futuro. Em Bauer, Cox, *et al.* (2007) o método da entropia de transferência foi utilizado para inferência de causalidade entre duas malhas de controle oscilando na mesma frequência. Em Schindler (2011) é apresentado a equivalência entre os métodos entropia da transferência e causalidade de Granger para sinais com distribuição gaussiana.

A proposta neste trabalho é utilizar o método da causalidade proposto por Granger (1969) para determinar as relações de causalidade entre as variáveis agrupadas. Esse método detecta a causalidade entre dois sinais através da comparação do erro de previsão de uma malha com e sem a inclusão da outra malha no cálculo do modelo auto-regressivo. Conclui-se que  $x_1$  causa  $x_2$  caso o erro de previsão do modelo auto-regressivo de  $x_2$  reduz ao se adicionar a informação passada de  $x_1$ . Dados dois sinais  $x_1$  e  $x_2$  no tempo de comprimento  $N$ , os parâmetros do modelo auto-regressivo,  $a_j$  e  $b_j$ , podem ser calculados utilizando

$$x_{1t} = \sum_{j=1}^p a_j x_{1t-j} + n_{11} \quad (2.17)$$

$$x_{2t} = \sum_{j=1}^p b_j x_{2t-j} + n_{22} \quad (2.18)$$

e estimação por mínimos quadrados. Os parâmetros dos modelos interdependentes,  $a_j^{11}$ ,  $a_j^{12}$ ,  $b_j^{21}$  e  $b_j^{22}$ , podem ser obtidos utilizando

$$x_{1t} = \sum_{j=1}^p a_j^{11} x_{1t-j} + \sum_{j=1}^p a_j^{12} x_{2t-j} + n_{21} \quad (2.19)$$

$$x_{2t} = \sum_{j=1}^p b_j^{21} x_{1t-j} + \sum_{j=1}^p b_j^{22} x_{2t-j} + n_{12} \quad (2.20)$$

e estimação por mínimos quadrados novamente, onde  $j$  é o índice do parâmetro, variando de 1 a  $p$ , e  $p$  é a ordem do modelo. Os vetores  $n_{11}$ ,  $n_{12}$ ,  $n_{21}$  e  $n_{22}$  são os resíduos da regressão não correlacionados, com variância  $\sigma_{n_{11}}^2$ ,  $\sigma_{n_{12}}^2$ ,  $\sigma_{n_{21}}^2$  e  $\sigma_{n_{22}}^2$  respectivamente.

Considerando (2.18) e (2.20), se  $\sigma_{n_{12}}^2 < \sigma_{n_{22}}^2$ , a variabilidade do erro do modelo considerando os valores de  $x_1$  e  $x_2$  é menor que a do modelo utilizando somente os valores de  $x_2$ , então pode-se afirmar que  $x_1$  causa  $x_2$ . Esta causalidade pode ser quantificada por (Ding, Bressler, *et al.*, 2000)

$$F_{1 \rightarrow 2} = \ln \frac{\sigma_{n_{22}}^2}{\sigma_{n_{12}}^2} \quad (2.21)$$

e uma matriz de causalidade pode ser obtida pela aplicação do método a cada par de variáveis. Para o caso de  $m$  sinais, ela é dada por:

$$F = \begin{bmatrix} 0 & F_{2 \rightarrow 1} & \dots & F_{m \rightarrow 1} \\ F_{1 \rightarrow 2} & 0 & & F_{m \rightarrow 2} \\ \vdots & & \ddots & \vdots \\ F_{1 \rightarrow m} & F_{2 \rightarrow m} & \dots & 0 \end{bmatrix} \quad (2.22)$$

Nesta matriz, o elemento  $ij$  de  $F$  representa a causalidade da  $j$ -ésima variável na  $i$ -ésima variável.

A matriz de causalidade permite a construção de um grafo direcionado e através dele pode-se buscar a fonte. A matriz de adjacência foi utilizada em Jiang, Patwardhan e Shah (2009) para diagnosticar a fonte de oscilações, tendo sido construída a partir de informações do processo. Esta matriz é composta por elementos com valores “1”s ou “0”s somente, podendo ser obtida diretamente da matriz de causalidade. Se a variável  $i$  causa a variável  $j$ , o elemento  $ji$  é “1”.

Para cômputo da causalidade de Granger utilizou-se o *toolbox* GCCA (*Granger causal connectivity analysis*) do *Matlab* (Seth, 2010). Esse *toolbox* fornece uma série de funções para detecção da causalidade através do método de Granger. As tendências dos sinais são removidas com o objetivo de simplificar os modelos a serem estimados, e preparar os dados para o teste de estacionariedade. A ordem dos modelos é definida via critério de Akaike (Akaike, 1974) em um intervalo de ordens pré-definido. Os modelos estimados têm sua qualidade avaliada por uma medida chamada consistência, dada por (Ding, Bressler, *et al.*, 2000):

$$C = \left( 1 - \frac{|R_S - R_R|}{R_R} \right) \times 100 \quad (2.23)$$

onde  $R_R$  é o vetor de correlação dos dados originais e  $R_S$  é o vetor de correlação dos dados gerados através do modelo. Cada vetor é um vetor linha (de comprimento  $N^2$ ) obtido da matriz de covariância correspondente. Em Seth (2010) sugere-se que a consistência média dos modelos seja maior que 80%, e caso haja modelos com consistência inferior a 30% a análise deve ser refeita ou rejeitada.

Um pré-requisito para aplicação do método de Granger é a estacionariedade dos dados, sendo uma exigência recorrente nas fontes citadas durante a apresentação do método. Entretanto a estacionariedade não garante a convergência dos parâmetros do modelo de regressão para um valor único, independentemente da escolha dos regressores. Para garantir a convergência dos parâmetros, é necessário avaliar a persistência da excitação, que avalia a atividade do sinal em regime permanente, determinando se esse é adequado para a identificação de modelos. Um sinal estacionário  $y(t)$  é persistentemente excitante se

$$E[y(t)y^T(t)] > 0 \quad (2.24)$$

Sendo assim, a persistência é garantida se o sinal  $y$  é limitado e tende a ser não nulo com o decorrer do tempo.

Em processos industriais mudanças de ponto de operação, níveis de produção e *setpoint* são frequentes, o que garante a multimodalidade do processo. Em processos multimodais, um conjunto de dados com um grande número de amostras provavelmente não será estacionário. Entretanto, na maior parte dos casos, o uso de tais dados permite uma apropriada identificação dos parâmetros do modelo. Em Ljung (1999) o conceito de quase-estacionariedade é introduzido, onde as condições para haver estacionariedade são relaxadas, permitindo que a média e a variância tenham valores limitados, não sendo necessário a convergência para valores constantes. Desta forma devido as dificuldades em

se atender aos requisitos da estacionariedade e aos problemas oriundos da utilização de técnicas para tornar dados estacionários, os sinais serão avaliados se atendem a quase-estacionariedade, de forma a verificar se os dados são adequados para a obtenção de modelos.

Finalmente, a significância dos modelos é calculada. Verifica-se se os coeficientes de um modelo são significativamente diferentes de zero por meio de um teste  $F$  para a hipótese nula de que são zero (Seth, 2010).

Quando o conjunto de sinais a ser analisado é muito grande, a análise de causalidade condicional, usando todas as variáveis ao mesmo tempo, não deve ser realizada, pois gera matrizes com número de condição muito baixo. A sugestão feita em Seth (2010) é calcular nesses casos a causalidade para variáveis par a par.

A matriz de causalidade permite inferir possíveis causas de falha. Uma linha nula indica que a variável correspondente não é afetada pelas demais, o que já indicaria a fonte. A existência de realimentações, comuns para reaproveitamento de energia, podem fazer com que não se possa detectar uma malha de controle que não seja afetada por nenhuma outra malha. Nesse caso ela seria afetada por poucas variáveis, o que permitiria reduzir consideravelmente o esforço de análise da operação, pois apenas as variáveis afetadas seriam analisadas.

Vários *softwares* comerciais foram desenvolvidos para monitorar o desempenho de malhas de controle, sendo apresentados na Tabela 1 (Jelali, 2006). Eles auxiliam as equipes de manutenção através do computo de KPIs (*key performance indicator*) de forma a classificar as malhas de controle com pior desempenho, onde a manutenção deve ser priorizada. Entretanto, no caso da ocorrência de falhas, o trabalho de isolar a fonte fica para o usuário na maior parte desses *softwares*. Alguns desses *softwares* se propõem a identificar a fonte da falha utilizando a correlação entre os sinais monitorados, entretanto, esta análise pode guiar a resultados não conclusivos conforme mencionado anteriormente.

Tabela 1 – Softwares para monitoramento desempenhos em malhas de controle

<b>Empresa</b>	<b>Endereço Eletrônico</b>	<b>Nome do Produto</b>
Matrikon	(www.matrikon.com)	ProcessDoctor
ExperTune	(www.expertune.com)	PlantTriage
ProControl Technology	(www.pctworld.com)	PCT Loop Optimizer Suite (PCT LOS) a
ABB	(www.abb.com)	OptimizeIT Loop Performance Manager (LPM)
Honeywell	(www.acs.honeywell.com)	Loop Scout
Emerson Process Management	(www.emersonprocess.com)	EnTech Toolkit, DeltaV Inspect
ControlSoft	(www.controlsoftinc.com)	INTUNE
		KCL-Control-Performance Analysis
KCL	(www.kcl.fi)	(KCL-CoPA)
OSIsoft	(www.osisoft.com)	PI ControlMonitor
AspenTech	(www.aspentech.com)	Aspen Watch
Control Arts Inc.	(www.controlartsinc.com)	Control Monitor
Invensys	(www.invensys.com)	Loop Analyst
PAS	(www.pas.com)	ControlWizard
Metso Automation	(www.metsoautomation.com)	LoopBrowser
PAPRICAN	(www.paprican.ca)	LoopMD

Neste trabalho é proposto um método para detectar, identificar e diagnosticar falhas, utilizando as relações de causalidade entre sinais para indicar a(s) fonte(s) de onde se originou a falha. A detecção de falhas é realizada com a combinação da análise por componentes principais com as estatísticas  $T^2$  e  $Q$ . A seleção dos sinais afetados é feita utilizando a análise univariada por cartas de controle e multivariada usando PCA. O método de causalidade de Granger é aplicado nos sinais agrupados para a determinação das relações de causalidade e posterior busca pela fonte. A vantagem desta abordagem, além da detecção da falha, está no agrupamento somente dos sinais afetados por uma falha, através da análise estatística, eliminando sinais não relacionados a ela, o que aumenta muito a eficiência do método de computo de causalidade.

## Capítulo 3: Metodologia proposta

O diagnóstico de falhas em plantas industriais pode ser realizado de maneira *online* ou *off-line*, dependendo da necessidade do processo. Métodos *online* possibilitam o diagnóstico de falhas em tempo real, tão logo aconteçam. O diagnóstico *off-line* consiste na utilização de uma metodologia de análise dos dados após a percepção de uma falha pela operação, de forma a isolar a parte do processo onde ocorreu, sendo esta a proposta deste trabalho.

A análise *online* exige que os modelos utilizados se adaptem a variações de pontos de operação, situação muito comum em ambientes industriais, não sendo abordada neste trabalho. Uma extensão do método para plantas com múltiplos pontos de operação é possível utilizando o conceito agrupamento de dados (*data clustering*), que é a seleção de múltiplos dados de treinamento para diferentes pontos de operação da planta (Maestri, Farall, *et al.*, 2010). Um teste para calcular a distância de cada nova amostra para cada grupo de dados é realizado, selecionando o modelo PCA e os limiares de detecção de falhas a serem utilizados.

A tarefa de isolar as fontes de uma falha mesmo tendo consciência de sua ocorrência não é fácil. Geralmente não se tem conhecimento do instante de tempo de sua ocorrência e um grande conjunto de variáveis são por ela afetadas, tornando a análise complexa e onerosa. Nesse contexto, um método capaz de detectar, identificar e diagnosticar uma falha, isolando o sinal ou o conjunto de sinais onde ela ocorreu (fonte) é de extrema valia para a equipe de operação e manutenção de uma planta. Normalmente, o diagnóstico de falhas é tratado como um problema de classificação de padrões (Venkatasubramanian, Rengaswamy, *et al.*, 2003). A proposta neste trabalho é utilizar o método de causalidade de Granger para diagnosticar a falha entre as variáveis que foram afetadas pela mesma, dispensando assim a necessidade desses padrões para isolar as falhas.

A aplicação direta dos métodos de causalidade aos resultados da detecção e isolamento de falhas não é possível devido a principalmente três problemas:

- Encontrar uma única fonte da falha muitas vezes não é possível;
- A aplicação dos métodos de causalidade num conjunto grande de sinais tende a gerar resultados inconclusivos, devido a inclusão de relações de causalidade entre variáveis que não foram efetivamente afetadas pela falha;
- O método de isolamento de falhas usando estatística  $T^2$  de Hotelling e PCA pode incluir na análise variáveis que não foram afetadas pela falha, conforme será detalhado mais à frente.

### 3.1 Obtenção do modelo PCA

Um importante passo na correta utilização da análise por componentes principais está na correta definição dos dados de treinamento para obtenção do modelo PCA. A quantidade de dados deve ser grande o suficiente para reproduzir a variabilidade natural dos sinais, mas com o cuidado de não incluir trechos sob a influência de uma falha. No presente trabalho assume-se que a definição do período de treinamento será feita pela equipe operacional.

A definição do número de componentes a serem selecionadas depende do limiar de variabilidade dos dados que se deseja representar. O método de percentual da variância (seção 2.1.3) foi utilizado neste trabalho para seleção das componentes principais, sendo necessária a definição do limite percentual que represente significativamente a variabilidade de cada conjunto de dados.

Definindo-se o nível de significância requerido para o conjunto de sinais, é possível calcular os limites controle para ambos índices estatísticos.

### 3.2 Detecção da Falha

Uma vez calculado o modelo PCA, é possível acompanhar o comportamento estatístico do conjunto de sinais através dos índices estatísticos  $T^2$  e  $Q$  (secção 2.1.4), de forma a determinar se estes estão em controle estatístico.

Os índices  $T^2$  e  $Q$  são calculados para cada nova amostra dos dados. Pontos da estatística que ultrapassem ambos os limites de controle estipulados, devem ser considerados como fora de controle estatístico e, conseqüentemente, sob efeito de uma falha. De forma a evitar a geração de falsos alarmes, conforme exemplificado na secção 2.1.1, os valores gerados pelos índices estatísticos foram filtrados por um filtro EWMA.

### 3.3 Identificação da falha

Após a detecção da presença de uma falha, o primeiro ponto após a violação do limite estatístico é utilizado para análise da contribuição de cada variável para a violação, conforme procedimento detalhado na secção 2.2. Variáveis com contribuição percentual inferior a um limite mínimo de 1% não são selecionadas.

### 3.4 Análise univariada

A análise por componente principais é um método baseado na captura da correlação entre os sinais contidos nos dados de treinamento, sendo muito eficiente na tarefa de detecção de uma falha. Entretanto, no que diz respeito a seleção dos sinais que tiveram um aumento de sua variância durante a falha, a utilização puramente do critério de sua contribuição para a violação, pode incluir sinais que não foram afetados pela falha, incluídos apenas por possuírem uma forte correlação com aqueles que foram afetados. O exemplo a seguir ilustra esta situação.

O exemplo utiliza três sinais simulados aleatórios no tempo não correlacionados, com uma falha acontecendo em somente em um dos sinais, de forma a ilustrar a utilização das análises univariada e multivariada na identificação da falha. Considerando três sinais no tempo  $x_1$ ,  $x_2$  e  $x_3$  com número de amostras  $N$  igual a 2.000, gerados da seguinte forma

$$x_{1t} = 0,5x_{1t-1} + r_{1t} \quad (3.1)$$

$$x_{2t} = 0,7x_{2t-1} + r_{2t} + f_t \quad (3.2)$$

$$x_{3t} = 0,6x_{3t-1} + r_{3t} \quad (3.3)$$

$$f_t = \begin{cases} 4, & \text{Se } 1.000 \leq t \leq 1.500 \\ 0, & \text{Se } t < 1.000 \text{ e } t > 1.500 \end{cases} \quad (3.4)$$

onde  $r_i(t)$ ,  $i = 1,2,3$  são sinais aleatórios com média zero e desvio padrão unitário. O sinal  $f$  simula uma falha no sinal  $x_2$ . Na Figura 5 é mostrado o comportamento temporal dos sinais.



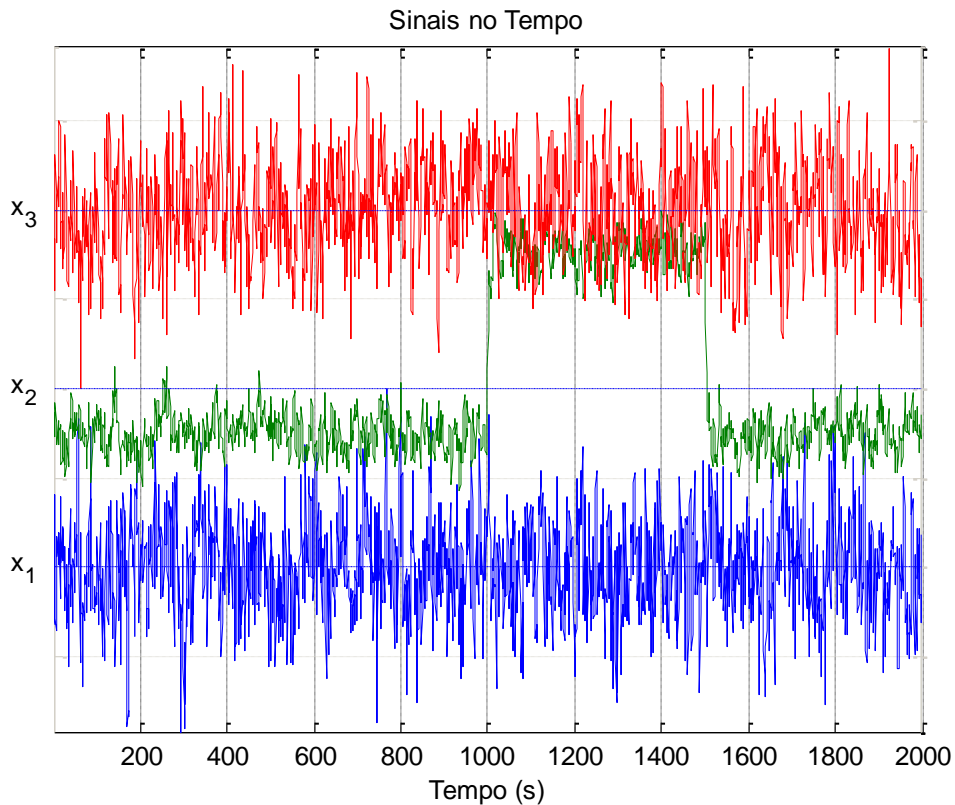


Figura 5- Sinais  $x_1$ ,  $x_2$  e  $x_3$  no tempo

O teste estatístico  $T^2$  foi calculado no intervalo de amostras de 1 a 2.000 utilizando a equação (2.9), sendo apresentado na Figura 6. É possível perceber que há uma alteração no comportamento em torno da amostra 1.000, onde a falha  $f$  é detectada (indicada pela marca vermelha). O modelo PCA foi calculado utilizando as amostras de 1 a 900 para treinamento e, as 3 componentes principais que foram selecionadas representam mais de 95% da variância total do sistema. A linha preta mostra o limite estatístico com um nível de significância de 99%, calculado em 11,45 através da equação (2.10). Um filtro EWMA foi utilizado na estatística  $T^2$  com um fator  $\alpha = 0,03$ .




Figura 6 -Estatística  $T^2$  para os sinais  $x_1, x_2$  e  $x_3$  no tempo

A análise das contribuições para violação do limite multivariado após mil repetições do experimento descrito acima, calculadas através dos passos definidos na secção 2.2, pode ser visualizada na Figura 7 utilizando *boxplots*. Como nesta primeira simulação os sinais foram gerados sem correlação e a falha ocorreu somente no sinal  $x_2$ , fica claro que  $x_2$  é o maior contribuidor e que a contribuição dos outros sinais pode ser desprezada. O teste univariado aplicado no mesmo conjunto de dados é apresentado na Figura 8, e mostra que somente o sinal  $x_2$  viola o limite de 3 desvios padrão (linha amarela), sendo este o único sinal fora de controle estatístico. Portanto neste experimento as análises univariada e multivariada apontaram o sinal  $x_2$  como o responsável pela falha.

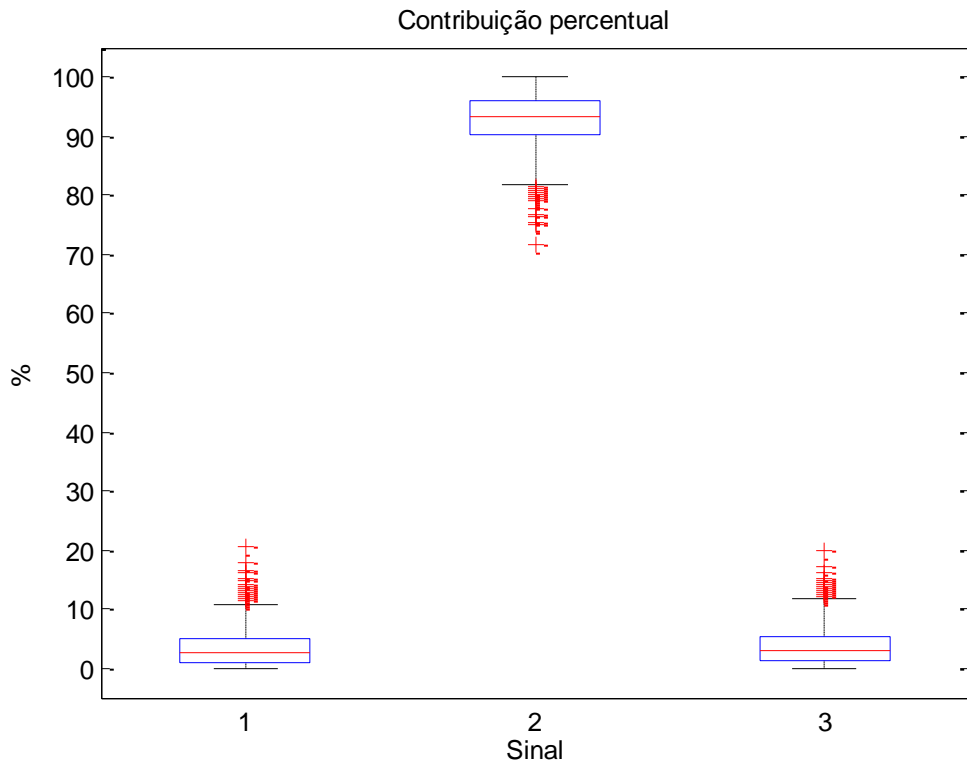


Figura 7 – Contribuições dos sinais  $x_1$ ,  $x_2$  e  $x_3$  para a violação do limiar




Figura 8 – Análise univariada dos sinais  $x_1$ ,  $x_2$  e  $x_3$

Agora, os três sinais são simulados novamente, sendo  $x_1$  e  $x_3$  gerados conforme equações (3.1) e (3.3), respectivamente. Uma correlação entre o sinal  $x_1$  e  $x_2$  é inserida através da alteração da equação (3.2) para

$$x_{2t} = 0,7x_{2t-1} + x_{1t-1} + r_{2t} + f_t \quad (3.5)$$

A Figura 9 mostra o comportamento do novo conjunto de dados no tempo.

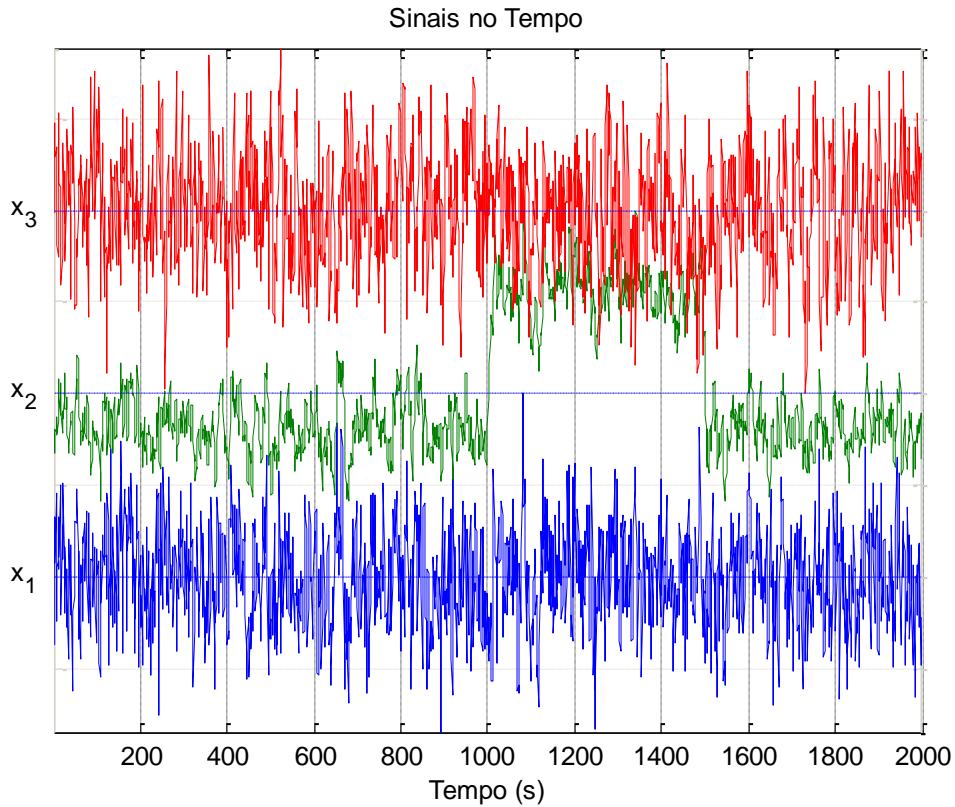


Figura 9- Sinais  $x_1, x_2$  e  $x_3$  no tempo, com  $x_1$  e  $x_2$  correlacionados

O teste estatístico  $T^2$  foi recalculado para o novo conjunto de dados no intervalo de amostras de 1 a 2.000, sendo apresentado na Figura 10. Novamente uma alteração no comportamento pode ser observada em torno da amostra 1.000, onde uma falha é detectada (indicada pela marca vermelha). O modelo PCA foi calculado utilizando as amostras de 1 a 900 para treinamento e, as 3 componentes principais que foram selecionadas representam mais de 95% da variância total do sistema. A linha preta mostra o limite estatístico com um nível de significância de 99%, calculado novamente em 11,45. Um filtro EWMA foi utilizado na estatística  $T^2$  com um fator  $\alpha = 0,03$ .




Figura 10 -Estatística  $T^2$  para os sinais  $x_1, x_2$  e  $x_3$  no tempo, com  $x_1$  e  $x_2$  correlacionados

Na Figura 11 são apresentadas as contribuições para a falha de cada sinal após mil repetições do mesmo experimento. As contribuições dos sinais  $x_1$  e  $x_2$  são significativas para a falha, não sendo possível desprezar nenhum dos dois sinais. Entretanto, sabe-se que a falha aconteceu somente em  $x_2$  entre as amostras de 1.000 a 1.500, não havendo alteração de comportamento no sinal  $x_1$  no período da falha. Isto demonstra que  $x_1$  foi incluído por possuir correlação com  $x_2$  e não por ter sido afetado pela falha. A inclusão de  $x_1$  poderia levar a uma conclusão equivocada no caso de uma análise de causalidade, uma vez que  $x_1$  causa  $x_2$  como pode ser visto na equação (3.5), o que indicaria  $x_1$  como fonte.

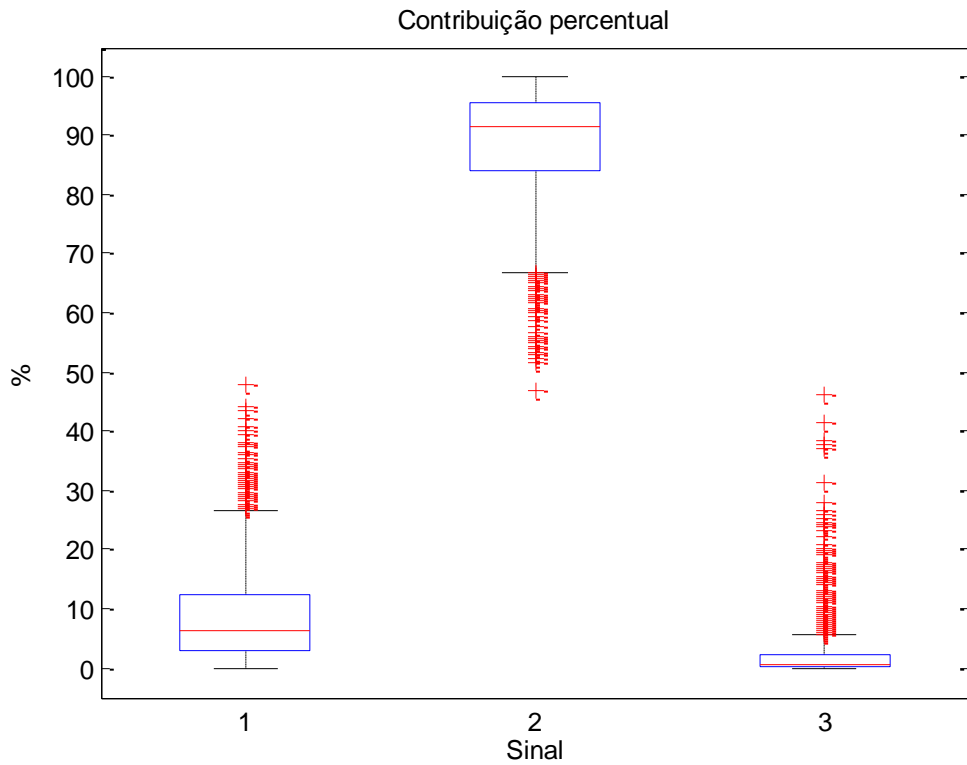


Figura 11 – Contribuições para a violação dos sinais  $x_1$ ,  $x_2$  e  $x_3$ , com  $x_1$  e  $x_2$  correlacionados

Na análise univariada apresentada na Figura 12 pode-se observar que somente  $x_2$  sofreu aumento em sua variabilidade e violou o limite de controle (3 desvios padrão), mostrando que somente  $x_2$  foi afetado pela falha. Desta forma, faz-se necessário um passo adicional após a análise de contribuições para manter somente os sinais que sofreram aumento em sua variabilidade.

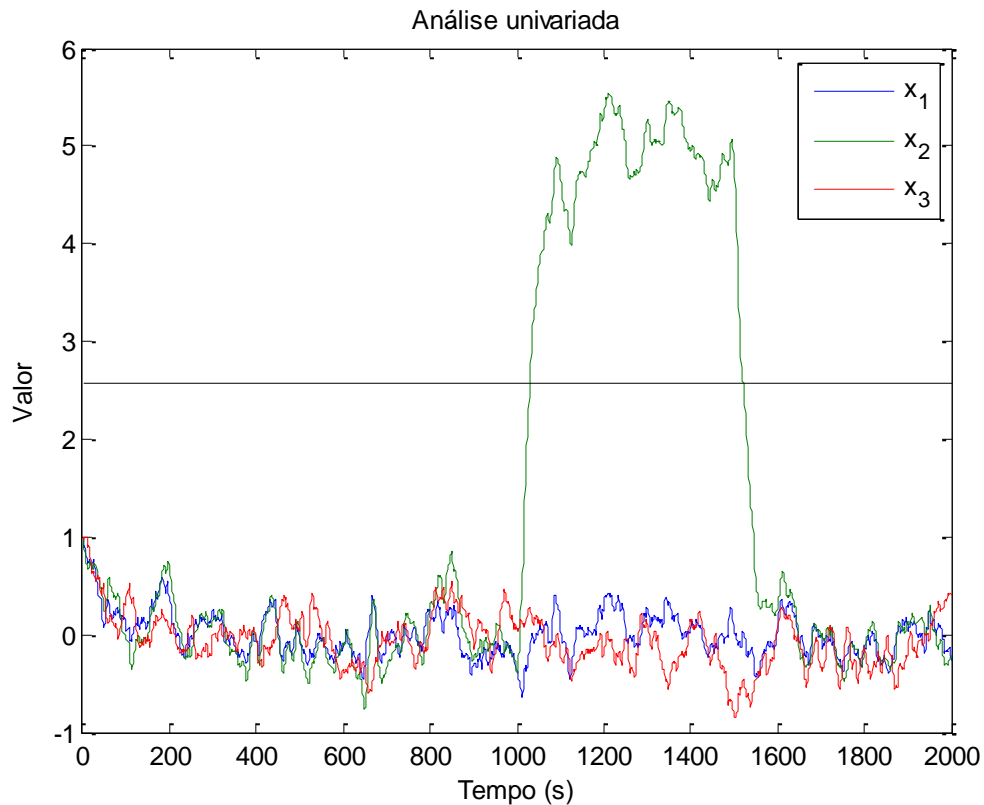


Figura 12 – Análise univariada dos sinais  $x_1$ ,  $x_2$  e  $x_3$ , com  $x_1$  e  $x_2$  correlacionados

De forma a mitigar o problema da inclusão de sinais por efeito da correlação, uma segunda análise, univariada, como as cartas de controle apresentadas no capítulo 2, será aplicada aos sinais selecionados pelo método multivariado, excluindo do grupo os sinais que não sofreram aumento de sua variabilidade no momento da falha. Para isto faz-se necessário definir o nível de confiança requerido para o conjunto de dados, que determinará o limite de controle. Mais uma vez é necessária a utilização de um filtro EWMA nos sinais, de forma a evitar a geração de falsos alarmes devido a influência do ruído.

A identificação de sinais baseada na sua contribuição para a violação possui outras limitações além da apresentada acima. Podem ocorrer casos em que nenhum *score* atenda ao critério de seleção definido pela equação (2.14). Nesse caso, a seleção de todos os *scores* pode contornar esta situação. Podem ainda haver casos onde as contribuições dos sinais são negativas, não sendo possível nesse caso a identificação dos sinais afetados. Entretanto, esses problemas tendem a não acontecer quando muitos sinais são analisados.

### 3.5 Diagnóstico da falha e busca pelas fontes

Uma vez selecionado o grupo de sinais afetados por uma falha, para encontrar a fonte é necessário conhecer as relações de causalidade entre os sinais. Nesta etapa o método de causalidade de Granger é aplicado no conjunto de sinais previamente selecionados, utilizando o mesmo conjunto de dados do período de treinamento do modelo PCA, ou seja, durante a operação normal. Nesses momentos os sinais operam em regiões de linearidade, adequados aos requisitos do método de Granger. Os momentos de falha geram distúrbios que podem tornar os sinais mais ricos para identificação, entretanto, comportamentos não lineares podem se manifestar, além da possibilidade de a falha afetar as relações de causalidade. Um transmissor ou atuador que entre em falha pode ter sinais a eles associados mantidos constantes.

O método de Granger multivariável será aplicado caso o número de sinais a serem analisados for menor que 10, caso contrário, será realizada a análise para a par. Este limite foi determinado a partir do conhecimento adquirido com a aplicação do método de Granger em vários conjuntos de dados, onde observou-se que o método multivariável passa a ter um número de condição muito baixo a partir deste limite. A faixa para determinar a ordem dos modelos via critério de Akaike deve ser definida para cada conjunto de dados. No caso do método de Granger multivariável a mesma ordem será utilizada para todos os modelos, já no caso par a par a ordem será determinada a cada par.

Os modelos cujo p-valor, para o teste de hipótese de que os parâmetros são significativamente diferentes de zero, for menor que 0,01 serão considerados, bem como, a consistência dos modelos gerados deve ser maior que 30%.

O passo final do procedimento é buscar na matriz de causalidade de Granger os sinais que possam ser indicados como fonte da falha. Sinais que afetam vários outros e que não são afetados são candidatos a fonte, podendo a fonte ser única ou múltipla. Entretanto, devido a presença de realimentações de processo com o intuito de reaproveitamento de energia, nem sempre é possível encontrar uma única fonte, uma vez que os sinais passam a ter uma forte interdependência. Em alguns casos, consegue-se chegar a um grupo pequeno de sinais a serem analisados de forma a encontrar a fonte, o que já é de grande valia para encontrar a causa do problema. Em outros casos, é possível determinar um grupo de variáveis que afeta outros, podendo-se indicar esse grupo como fonte. Existem ainda situações que não é possível chegar a um grupo pequeno de variáveis, ficando a indicação da fonte a cargo da equipe de operação através da utilização do conhecimento de processo.

O procedimento para detecção e diagnóstico de falhas proposto é realizado através dos seguintes passos:

- i. Obtenção do modelo PCA: definir um período de operação sob condições normais para cálculo do modelo PCA e determinação dos limites para as estatísticas  $T^2_{a,\alpha,n}$  e  $Q_\alpha$ ;
- ii. Detecção da Falha: Cálculo das estatísticas  $T^2$  e  $Q$  para cada nova amostra de dados, detectando o instante em que a falha ocorreu;
- iii. Identificação da falha: seleção das variáveis que mais contribuíram para a violação, eliminando aquelas que não sofreram aumento na sua variância durante a falha através da análise univariada;
- iv. Diagnóstico da falha: utilizar o método de causalidade de Granger para encontrar a relação de causalidade entre as variáveis remanescentes do passo iii, utilizando os mesmos dados de treinamento do modelo PCA;
- v. Busca pelas fontes: identificar a fonte ou as fontes que originaram a violação através da busca do grafo direcionado obtido no passo iv.

O objetivo principal no diagnóstico de falhas é a determinação da causa da falha. Mesmo não sendo possível determinar a causa da falha através do procedimento proposto, a informação do sinal ou sinais onde a falha se iniciou está bem próxima da causa da falha. Nesse caso um pequeno conhecimento do processo pode solucionar a causa da falha.

Este algoritmo pode ser executado pela equipe de operação cada vez que uma falha for detectada, com a informação histórica extraída do banco de dados. Sua aplicação *online* é possível se o processo operar próximo das mesmas condições do período de treinamento.



## Capítulo 4: Estudos de caso

Neste capítulo estudos de casos provenientes de diferentes processos industriais serão utilizados a fim de ilustrar a aplicação do método proposto no capítulo 3.

O capítulo está dividido em duas partes. Na primeira o método será aplicado em um conjunto de dados provenientes de uma central termelétrica de uma indústria siderúrgica. Na última parte, um conjunto de dados de um forno de pelotização serão analisados com a metodologia proposta. Em todos os casos, o objetivo é ser capaz de diagnosticar uma falha a partir de conjuntos de dados com operação normal e em com a presença de uma falha.

### 4.1 Central Termelétrica

O estudo de caso trata de uma das quatro centrais termelétricas que geram energia para uma planta siderúrgica. O processo de geração de energia termelétrica baseia-se na geração de energia elétrica através do calor produzido pela queima de combustíveis, preferencialmente gases gerados como subprodutos do processo de produção de aço (Barbosa O. Jr., 2009). A Figura 13 mostra o esquemático de uma central termelétrica com as principais malhas de controle.

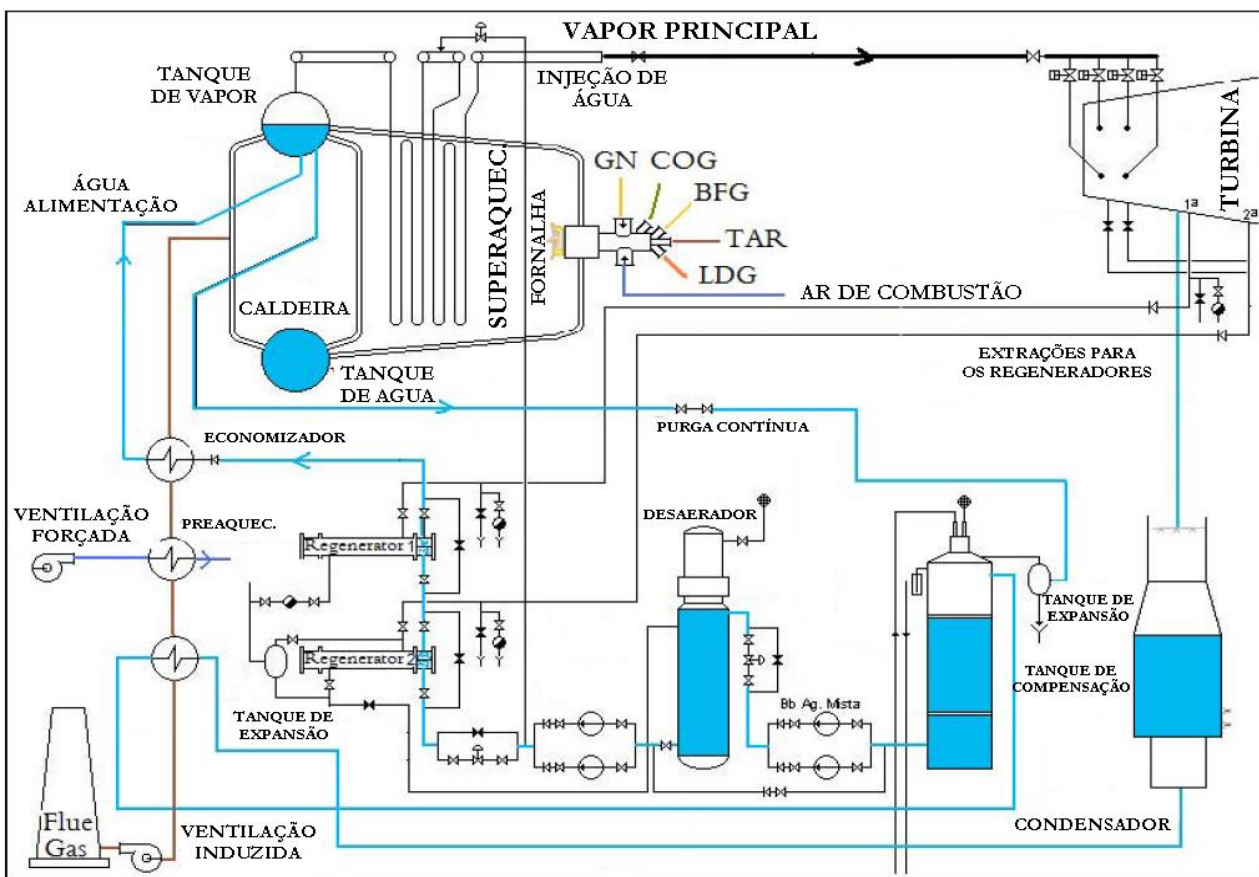


Figura 13 – Esquemático de uma central termelétrica

As termelétricas possuem papel fundamental em um processo siderúrgico fornecendo energia e vapor pressurizado para várias etapas da produção do aço. Possuem uma grande quantidade de malhas de controle, grande parte com algum acoplamento, e a análise de problemas sem qualquer ferramenta de ajuda é uma tarefa muito trabalhosa e lenta.

Para este trabalho foi selecionado um conjunto de 39 malhas de controle principais. Elas foram amostradas a cada 5s gerando um total de 8.640 amostras. Uma vez que um grande número de malhas de controle é afetado em torno do instante de tempo 440 minutos, o intervalo de tempo para treinamento foi [167 417] minutos e o intervalo de tempo para análise e diagnóstico da falha foi [417 500] minutos. O comportamento de parte das malhas de controle no tempo em torno do ponto de falha é ilustrado na Figura 14, as demais malhas não foram exibidas somente por restrições de clareza de visualização.




Figura 14 – Doze malhas de controle representativas da termelétrica no tempo em torno do ponto de falha

O modelo PCA foi calculado através dos dados de treinamento e as 24 componentes principais representando 95% da variância total do sistema foram selecionadas. Os limites para os testes estatísticos  $T^2$  e  $Q$  calculados através das equações (2.10) e (2.13), foram 43.78 e 4.6, respectivamente. Utilizando o modelo PCA, os testes estatísticos  $T^2$  e  $Q$  foram calculados, utilizando as equações (2.9) e (2.11), no intervalo de tempo selecionado para análise e diagnóstico da falha, e são apresentados na Figura 15. É possível perceber que os limites não são violados até o instante de tempo 440 minutos, aproximadamente, onde uma falha é detectada (indicada pela marca vermelha). A linha preta mostra os limites estatísticos para cada teste com um nível de 99% de significância. Um filtro EWMA foi utilizado nas estatísticas  $T^2$  e  $Q$  com um fator  $\alpha = 0,75$ .




Figura 15 – testes estatísticos  $T^2$  e  $Q$  da central termelétrica

Na Figura 16, é mostrado o percentual de contribuição de cada sinal para a violação do limite ilustrado na Figura 15, calculados através dos passos definidos na secção 2.2. Todas as malhas de controle representadas por um círculo azul cheio foram selecionadas para análise.




Figura 16 – Contribuição percentual de cada sinal para a violação do limite da central termelétrica (Círculo azul cheio - selecionado / Círculo azul vazio - não selecionado)

O teste univariado foi aplicado nas malhas de controle selecionadas no passo anterior em torno do ponto de falha, usando um intervalo de tempo entre 100 amostras antes da violação até 5 amostras após a violação, sendo apresentado na Figura 17. As malhas que não violaram o limite de controle (círculo azul), com nível de significância 99%, foram excluídas do grupo selecionado pela análise multivariada, por não terem sido afetadas pela falha. Aquelas que violaram o limite (círculo vermelho) foram afetadas e permanecem para a análise de causalidade.




Figura 17 – Resultado dos testes univariado da central termelétrica (Vermelho – selecionado / Azul – não selecionado)

Antes da aplicação do método de Granger para encontrar as relações causais entre estes 4 sinais, a ordem dos modelos de regressão foi obtida utilizando o critério Akaike, sendo igual a 26. As malhas de controle analisadas pelo método são apresentadas na Tabela 2. Na Tabela 3 a matriz de causalidade de Granger pode ser vista, com a consistência do modelo entre 74% a 95%. É possível perceber que a malha de controle 2 é afetada pelas malhas de controle 4 e 7, e somente afeta a malha de controle 7. As malhas de controle 4 e 7 afetam-se mutuamente. A malha de controle 5 não possui relação de causalidade com as demais malhas, e será excluída da análise. Mesmo que uma única fonte para a falha não tenha sido encontrada, somente três malhas de controle foram indicadas como possíveis fontes.

Tabela 2 – Malhas de controle da central termelétrica

Malha	Descrição
02	Controle da vazão de BFG para a fornalha
04	Controle da vazão do COG estabilizante
05	Controla a pressão do ar de combustão que é enviado para a fornalha
07	Malha mestre de vazão de combustível e ar de queima

Tabela 3 – Matriz de causalidade de Granger das malhas selecionadas da central termelétrica

SINAL	2	4	5	7
2	-	0,03	-	0,14
4	-	-	-	0,07
5	-	-	-	-
7	0,64	0,02	-	-

O conhecimento do processo é utilizado para validar os resultados. Na Figura 18 são mostrados os valores no tempo das malhas de controle indicadas como fonte. Claramente pode ser visto que a malha de controle 7, malha de controle mestre de vazão de combustível e ar de queima, teve uma alteração no seu ponto de operação, o que influenciou as malhas de controle 2 (controle da vazão de BFG para a fornalha) e 4 (controle do fluxo de COG estabilizante). A razão pela qual o procedimento não pode localizar uma fonte única utilizando somente a matriz de causalidade, está no fato de que estes sinais estão relacionados com o controle do fornecimento de combustível e estão fortemente relacionados.

Mesmo assim, o procedimento foi capaz de restringir o grupo de malhas a serem analisados de 39 para 3, tornando muito mais fácil a isolação da falha. A análise também deixa claro que, considerando a causa da falha, novas estratégias de controle devem ser projetadas para esta planta, de forma a prevenir sua propagação durante trocas nos *setpoints* das malhas de controle de combustível.

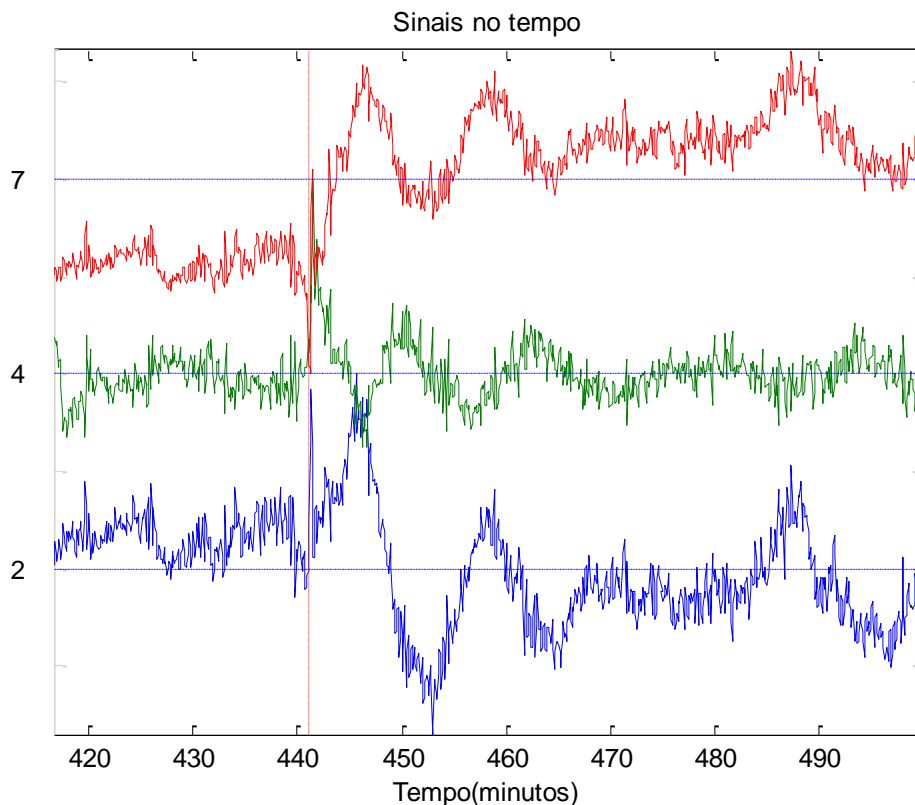


Figura 18 – Gráfico de tendência dos sinais em trono do ponto de falha da central termelétrica

## 4.2 Forno de pelotização

Este estudo de caso trata do forno de uma de oito usinas de pelotização de uma empresa Mineradora. O minério de ferro e o carvão mineral são os dois principais insumos do processo siderúrgico. A extração do minério de ferro gera um fino de minério como um subproduto, que não pode ser aproveitado diretamente na fabricação do aço, uma vez que sua baixa granulometria bloquearia a passagem de ar quente no alto-forno. O processo de pelotização consiste no reaproveitamento desse subproduto, aglomerando esse material em um produto de maior granulometria que pode ser aplicado diretamente nas etapas de aciaria e alto-forno. A Figura 19 mostra o esquemático de forno de pelotização.

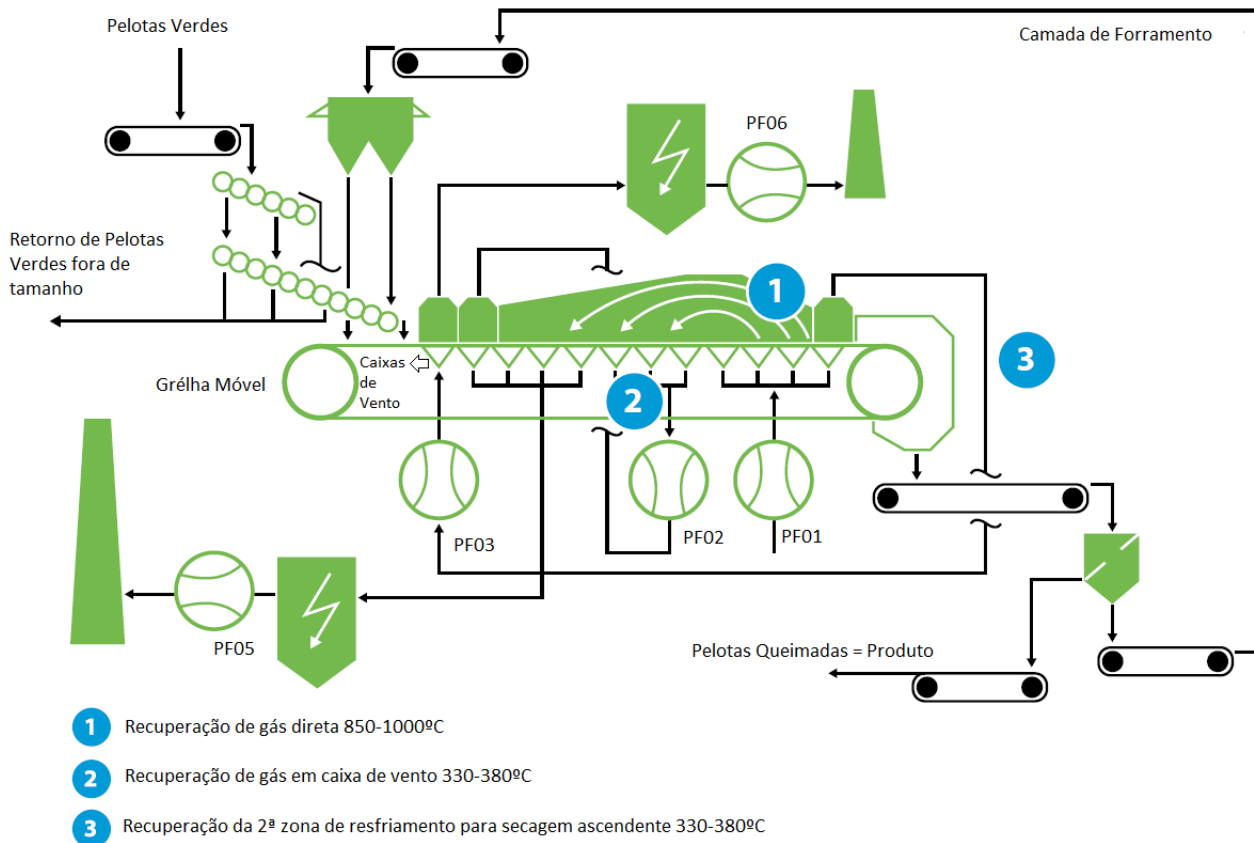


Figura 19 – Esquemático de um forno de pelotização (Outotec, 2015)

O forno de pelotização pode ser considerado como o coração do processo, uma vez que somente após esta etapa a mistura de fino de minério com aglomerante (pelota) adquire as propriedades mecânicas necessárias para o transporte e aplicação no processo siderúrgico, além de representar a etapa de maior custo de todo o processo. Possui uma grande complexidade devido a quantidade de sinais envolvidos, além do acoplamento entre eles provocado pelo reaproveitamento de energia. Desta forma uma ferramenta de auxílio na análise de problemas seria de grande valia para as equipes de manutenção e operação.

Para este trabalho foi selecionado um conjunto de 127 sinais principais, amostrados a cada 1s gerando um total de 86.400 amostras. Uma vez que um grande número de sinais é afetado em torno do instante de tempo 12,38 horas, o intervalo de tempo para treinamento foi [12,05 12,38] horas e o intervalo de tempo para análise e diagnóstico da falha foi [12,05 12,69] horas. O comportamento de parte dos sinais no tempo em torno do ponto de falha é ilustrado na Figura 20, os demais sinais não foram exibidos somente por restrições de clareza de visualização.




Figura 20 – Doze sinais representativos do forno de Pelotização no tempo em torno do ponto de falha

O cálculo do modelo PCA foi realizado através dos dados de treinamento e as 10 componentes principais representando 95% da variância total do sistema foram selecionadas. Os limites para os testes estatísticos  $T^2$  e  $Q$  calculados foram 23.56 e 12.62, respectivamente.

Através do modelo PCA, os testes estatísticos  $T^2$  e  $Q$  foram calculados no intervalo de tempo selecionado para análise e diagnóstico da falha, e são apresentados na Figura 21. É possível perceber que os limites não são violados até o instante de tempo 12.38 horas, aproximadamente, onde uma falha é detectada (indicada pela marca vermelha). A linha preta mostra os limites estatísticos para cada teste com um nível de significância de 99%. Um filtro EWMA foi novamente utilizado nas estatísticas  $T^2$  e  $Q$  com um fator  $\alpha = 0.12$ .

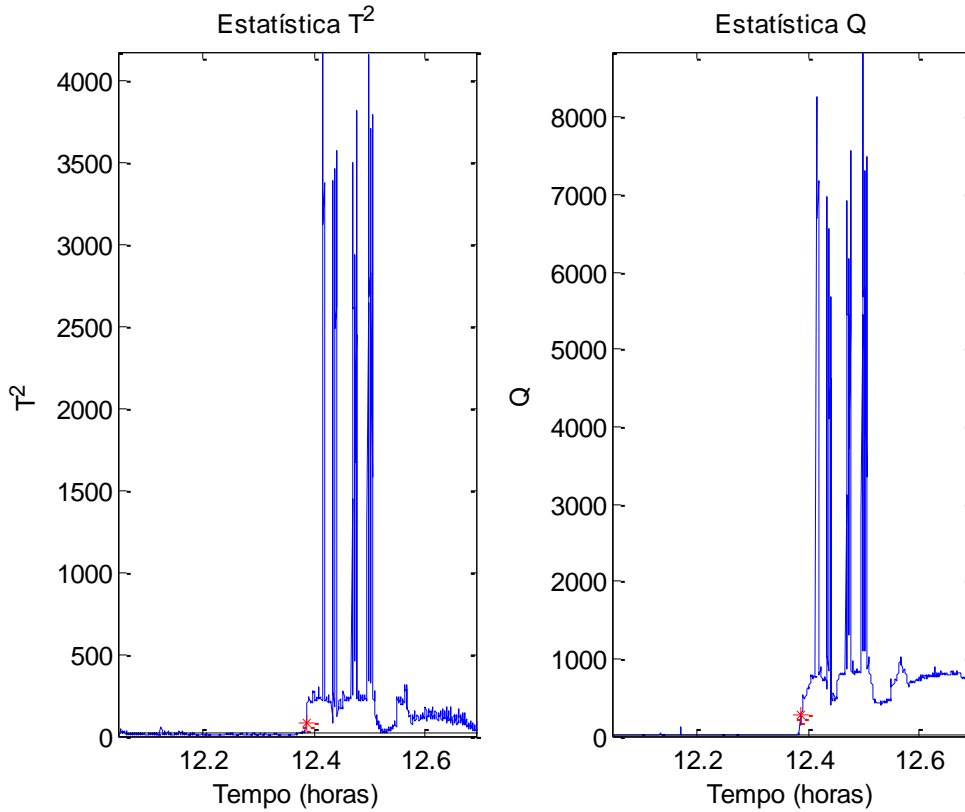


Figura 21 – testes estatísticos  $T^2$  e  $Q$  do forno de pelotização

Na Figura 22, é apresentado o percentual de contribuição de cada sinal para a violação do limite mostrado na Figura 21. Todos os sinais representados por um círculo azul cheio foram selecionados para análise.




Figura 22 – Contribuição percentual de cada sinal para a violação do limite do forno de pelotização (Círculo azul cheio - selecionado / Círculo azul vazio - não selecionado)



Novamente, o teste univariado foi aplicado nos sinais selecionados no passo anterior e aqueles que violaram o limite (nível de significância 99%) podem ser vistos na Figura 23 (marcadores vermelhos). A análise foi realizada no período de tempo em torno do ponto de falha, usando um intervalo de tempo entre 100 amostras antes da violação até 5 amostras após a violação. Pode-se perceber que neste caso todas os sinais selecionados pela análise multivariada foram mantidos pela análise univariada, o que significa que nenhum sinal foi incluído indevidamente por sua correlação com outro sinal afetado pela falha, diferente do que foi observado no estudo de caso apresentado na secção 4.1.




Figura 23 – Resultado do teste univariado do forno de pelotização (Vermelho – selecionado)

Antes da aplicação do método de Granger para encontrar as relações causais entre estes 7 sinais, a ordem dos modelos de regressão foi obtida utilizando o critério Akaike, sendo 16. O número e a descrição dos sinais a serem analisados podem ser vistos na Tabela 4. Na Tabela 5 a matriz de causalidade de Granger é apresentada, com a consistência dos modelos entre 40% a 99%. Na Figura 24 é apresentado um grafo direcionado construído através da matriz de causalidade onde as linhas verdes com seta indicam a causalidade em um único sentido e, as linhas vermelhas indicam causalidade nos dois sentidos. Através do grafo apresentado pode-se observar que somente o sinal 33 não é causado por nenhum outro e pode ser indicado como fonte. O sinal 33 causa os sinais 122 e 123, e o sinal 123, por sua vez, causa o sinal 48. Já os sinais 48 e 50 causam-se entre si. Os sinais 70 e 127 não possuem relação de causalidade com as demais e serão eliminados da análise.

Tabela 4 – Sinais do forno de pelotização

Sinal	Descrição
33	Controle de temperatura do ar de serviço do PF02
48	Controle de velocidade da grelha móvel
50	Medição de corrente da grelha móvel
70	Medição de temperatura do mancal ventilador do lado acoplado
122	Medição de temperatura na caixa de vento 16
123	Medição de temperatura na caixa de vento 17
127	Medição de temperatura na caixa de vento 21

Tabela 5 – Matriz de causalidade de Granger dos sinais selecionados do forno de pelotização

SINAL	33	48	50	70	122	123	127
33	-	-	-	-	-	-	-
48	-	-	0,43	-	-	0,03	-
50	-	0,05	-	-	-	-	-
70	-	-	-	-	-	-	-
122	0,05	-	-	-	-	-	-
123	0,04	-	-	-	0,04	-	-
127	-	-	-	-	-	-	-




Figura 24 – Grafo direcionado da matriz de causalidade do forno de pelotização

A causa da parada da produção já era conhecida e foi apontada pela operação como o desarme do PF02 por alta temperatura de ar de serviço. Analisando o comportamento temporal dos sinais envolvidos (Figura 25), podemos afirmar que a fonte indicada é bem consistente com a causa da parada atribuída pela operação, uma vez a malha 33 controla a temperatura do ar de serviço do ventilador PF02, que veio a aquecer acima do limite permitido ocasionando a parada do equipamento. Como a produção não pode continuar sem o funcionamento deste ventilador, por este afetar diretamente a qualidade do produto, a produção foi paralisada. A paralização da produção pode percebida pelo efeito nos sinais 48 e 50, que representam a produção da planta.

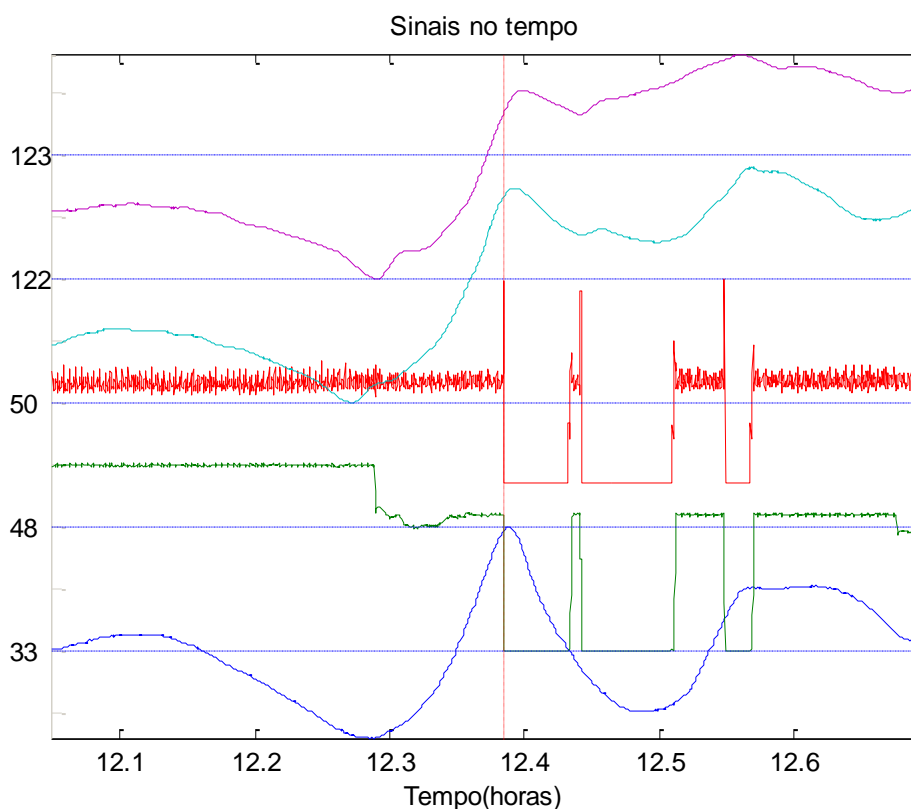


Figura 25 – Gráfico de tendência dos sinais em torno do instante de falha do forno de pelotização

Desta forma, o procedimento foi capaz de restringir o grupo de sinais a ser analisado de 127 para 2, tornando muito mais fácil a solução do problema. Além de indicar a causa da falha, eliminando a busca por outras fontes, a análise também deixa claro que novas estratégias de controle devem ser projetadas para esta planta, de forma a atuar preventivamente na temperatura de serviço do ventilador PF02 evitando assim a parada da produção.

Um fator muito importante para a correta aplicação do método está na escolha do período de tempo para os dados de treinamento, o que é fundamental para a correta seleção do conjunto de sinais afetados por uma falha. Outro fator importante está na escolha dos sinais que serão incluídos na análise, sinais demais, complicam a análise, além de incluir problemas secundários que podem afetar o desempenho do método. Sinais de menos, podem excluir importantes informações sobre o funcionamento do processo, impossibilitando o correto diagnóstico da falha.

A seleção do filtro deve ser ajustada para cada novo conjunto de dados de treinamento, pois se for muito grande, pode afastar demais o ponto de violação do momento da falha, de forma que se passa a analisar consequência e não a causa, o que pode incluir mais sinais do que necessário devido a propagação da falha pela planta. Se for muito pequeno, aumenta o número de falsos alarmes,

desacreditando o método perante a equipe de operação.

Em ambos os estudos de caso apresentados neste capítulo, a metodologia proposta foi capaz de diagnosticar a falha, indicando uma fonte única ou um grupo sinais. Para o caso da indicação de um grupo de sinais como fonte, fica a cargo do especialista do processo a determinação da origem do problema.

## Capítulo 5: Conclusão

Falhas em malhas de controle em processos industriais geralmente se propagam por várias malhas de controle, tornando difícil a indicação de suas fontes. Uma metodologia para indicar a fonte destas falhas foi proposta, utilizando controle estatístico multivariado para detectar o instante onde se iniciou, requerendo somente a indicação de um período de operação em condições consideradas normais. Os sinais afetados pela falha foram agrupados conferindo aqueles que mais contribuíram para a violação e, também, que violaram o teste estatístico univariado. Para isolar a fonte, o método de causalidade de Granger foi utilizado, uma vez que ele permite a construção de um grafo que relaciona os sinais agrupados. O procedimento foi aplicado em dois estudos de caso reais da indústria obtendo excelentes resultados, podendo ser aplicado automaticamente caso o processo opere próximo as condições do período de treinamento, detectando falhas e suas fontes.

Mesmo o método não sendo capaz de prover a causa da falha, a informação do sinal que causou a falha em questão é preciosa para as equipes de operação para o diagnóstico da falha. O que pode ser percebido pelos estudos de caso apresentados neste trabalho.

O método de Granger assume linearidade nos dados, o que é uma consideração perfeitamente aceitável para boa parte das plantas industriais, uma vez que esta consideração é a base para a geração de modelos de predição de processo em grande parte dos métodos de identificação, utilizados largamente na indústria. Para processos onde a linearidade não pode ser assumida, outros métodos de causalidade devem ser utilizados, como o método da entropia de transferência (Schreiber, 2000).

A extensão do método para plantas com múltiplos pontos de operação é possível utilizando o conceito agrupamento de dados proposto em Maestri, Farall, *et al.* (2010). Outra forma é o acompanhamento de sinais representativos para o processo, como variáveis que representam o patamar de produção (ex. potência gerada para uma termelétrica), onde poderia ser calculado um modelo PCA para cada patamar de produção.

A aplicação desta metodologia em sinais provenientes de medições de proteção de equipamentos de grande porte é um campo promissor de estudos, uma vez que pode ser utilizada para diagnosticar falhas ou, até mesmo, antever uma possível parada do equipamento monitorado.

## Referências Bibliográficas

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automation Control**, 1974. 19:716–723.
- BARBOSA O. JR., V. Modelagem de central termelétrica a vapor para simulação dinâmica. **Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito**, Vitória, 2009.
- BAUER, M. Finding the Direction of Disturbance Propagation in a Chemical Process Using Transfer Entropy. **IEEE Transactions on Control Systems Technology**, 2007. Volume 15, NO. 1, 12-21.
- BAUER, M.; THORNHILL, N. F. A practical method for indentifying the propagation path of plant-wide disturbances. **Journal of Process Control**, 2008. Volume 18, 707-719.
- BEZERGIANNI, S.; KALOGIANNI,. Application of Principal Component Analysis for Monitoring and Disturbance Detection of a Hydrotreating Process. **Ind. Eng. Chem. Res.** **47 (18)**, 2008. 6972–6982.
- CAMPOS, A. A. Um algoritmo de detecção de falhas em sistemas multivariados. **Universidade Federal de Minas Gerais - Programa de Pós-Graduação em Engenharia Elétrica - Dissertação de Mestrado**, Belo Horizonte, 17 Janeiro 2011.
- CHIANG, L. H.; RUSSELL, E. L.; BRAATZ, R. D. **Fault Detection and Diagnosis in Industrial Systems**. [S.l.]: Springer-Verlag London Limited, 2002.
- DEPIZZOL, C. F. Contribuições ao problema de detecção automática de oscilações em malhas de controle. **Programa De Pós-Graduação Em Engenharia Elétrica - Universidade Federal Do Espírito Santo (UFES) - Dissertação de Mestrado**, Vitória, Brasil, 2011.
- DING, M. et al. Short-window spectral analysis of cortical event-related potentials by adaptive multivariate autoregressive modeling: data preprocessing, model validation, and variability assessment. **Biological cybernetics**, vol. **83**, 2000. 35-45.
- FORSMAN, K. A. S. A.; STATTIN, A. A new criterion for detecting oscillations in control loops. **In European control conference**, Karlsruhe, Germany, 1998.
- GRANGER, C. W. J. Investigating causal relations by econometric models and crossspectral methods. **Econometrica** **37(3)**, 1969. 424-438.
- HÄGGLUND, T. A control-loop performance monitor. **Control Engineering Practice**, **3(11)**, 1995. 1543 – 1551.
- HOWARD, D. **Management- The basics of statistical rocess control & process behaviour charting**. 1st Edition. ed. [S.l.]: Management-NewStyle, 2003. ISBN ISBN : 0-9543866-5-5. Disponível em: <www.firstmetre.co.uk>.
- ISERMANN, R.; BALLÉ, P. Trends in the application of model-based fault detection and diagnosis of technical processes. **Control Eng. Practice**, 1997. Vol. 5, No. 5, 709-719.

- JELALI, M. An overview of control performance assessment technology and industrial applications. **Control Engineering Practice** **14**, 2006. 441–466.
- JIANG, H.; PATWARDHAN, ; SHAH, S. L. Root cause diagnosis of plant-wide oscillations using the concept of adjacency matrix. **Journal of Process Control** **19**, 2009. 1347–1354.
- KARRA, S.; KARIM, M. N. Comprehensive methodology for detection and diagnosis of oscillatory control loops. **Control Engineering Practice**, **17(8)**, 2009. 939 – 956.
- KOURTI, T. Process Analysis and Abnormal Situation Detection - From Theory to Practice. **IEEE Control Systems Magazine**, ago. 2002. 0272-1708/02©2002IEEE, 10-25.
- KOURTI, T.; MACGREGOR, J. F. Process analysis, monitoring and diagnosis, using multivariate projection methods. **Chemometrics and Intelligent Laboratory Systems** **28**, 1995. 3-21.
- LJUNG, L. **System Identification: Theory for the User**. 2<sup>a</sup>. ed. [S.l.]: Prentice-Hall, 1999.
- MAESTRI, M. . et al. A robust clustering method for detection of abnormal situations in a process with multiple steady-state operation modes. **Computers and Chemical Engineering**, 2010. Volume 34, 223–231.
- MIAO, T.; SEBORG, D. E. Automatic detection of excessively oscillatory feedback control loops. **IEEE International Conference**, 1999. volume 1, 359 –364.
- MONTGOMERY, D. C. **Introduction to Statistical Quality Control**. 6th. ed. [S.l.]: John Wiley & Sons, 2009.
- OUTOTEC. **Outotec English Website**. Disponível em: <<http://www.outotec.com/>>. Acesso em 25 ago. 2015.
- PAGE, E. S. Continuous inspection schemes. **Biometrika** , 1954. Volume 41, 100-115.
- SCHINDLER, C. H.; VERDES, P. F. Computational Intelligence approaches to causality detection. **European Symposium on Artificial Neural Networks**, Bruges (Belgium), 25-27 April 2007. ISBN 2-930307-07-2.
- SCHINDLER, K. H. Equivalence of Granger Causality and Transfer Entropy: A Generalization. **Applied Mathematical Sciences**, **Vol. 5, no. 73**, Vienna, Austria, 2011. 3637 - 3648.
- SCHREIBER, T. Measuring Information Transfer. **Phys. Rev. Lett.** **85**, 2000. 461.
- SETH, A. K. A MATLAB toolbox for Granger causal connectivity analysis. **Journal of Neuroscience Methods** **186**, 2010. 262–273.
- SHEWHART, W. A. **Economic control of quality of manufactured product**. Princeton, NJ: Editora Van Nostrand., 1931.
- STOCKMANN, M.; HABER, ; SCHMITZ., Source identification of plant-wide faults based on k nearest neighbor time delay estimation. **Journal of Process Control** **22**, 2012. 583– 598.
- THAMBIRAJAH, J. et al. Cause-and-effect analysis in chemical processes utilizing XML, plant

connectivity and quantitative process history. **Computers and Chemical Engineering** **33**, 2009. 503 – 512.

THORNHILL, N. F; HÄGGLUND, T. Detection and diagnosis of oscillation in control loops. **Control Engineering Practice**, 1997. Volume 5, Issue 10, 1343 – 1354.

THORNHILL, N. F. et al. Spectral principal component analysis of dynamic process data. **Control Engineering Practice**, 2002. Volume 10, 833–846.

THORNHILL, N. F.; COX, J. W.; PAULONIS, M. A. Diagnosis of plant-wide oscillation through data-driven analysis and process understanding. **Control Engineering Practice**, 2003. Volume 11, 1481–1490.

VENKATASUBRAMANIAN, et al. A review of process fault detection and diagnosis Part III: Process history based methods. **Computers and Chemical Engineering**, 22 Abril 2003, Volume 27, 327-346.

VILLEGAS, T.; FUENTE, M. J.; RODRÍGUEZ,. Principal Component Analysis for Fault Detection and Diagnosis Experience with a pilot plant. **9th WSEAS International**, Cambridge, UK, 2010. 147-152.

XIA, C.; HOWELL, ; THORNHILL, N. F. Detecting and isolating multiple plantwide oscillations via spectral independent component analysis. **Automatica**, 2005. Volume 41(12), 2067-2075.

YUAN, T.; QIN, S. J. Root cause diagnosis of plant-wide oscillations using Granger causality. **Journal of Process Control**, 2014. Volume 24, 450-459.

ZUQUI, G. C.; MUNARO, C. J. Diagnóstico de fontes de distúrbios em processos industriais via causalidade de Granger. **XI IEEE/IAS International Conference on Industry Applications – INDUSCON**, Juiz de Fora, Brasil, 2014.