# DETECÇÃO E DIAGNÓSTICO DE FALHAS EM SISTEMA DE TANQUES ACOPLADOS

Davi Fiorese Bissoli\* Celso José Munaro<sup>†</sup>

\*Departamento de Engenharia Elétrica Universidade Federal do Espírito Santo - UFES Av. Fernando Ferrari, 514 - Campus Universitário Vitória, ES, Brasil CEP 29075-910

Email: bissolidavi2@gmail.com, celso.munaro@ufes.br

Abstract— The application of multivariate statistical techniques has increasingly become an advantageous alternative for the detection and diagnosis of failures due to the great availability of data in industrial automation systems. The existence of benchmarks that reproduce the behavior of industrial processes contributes to the development of new techniques. In this work, the quadruple tank process, originally proposed for the development of multivariate control techniques, is explored for the evaluation of newly developed fault detection techniques for processes operating at different points of operation. The usual failures in real processes are introduced into the model as well as alternatives to operate the process in different regions. A methodology is proposed to generate data for training and testing of a diagnostic system with the ability to differentiate failures from point of operation changes. Even though it is trained with only one operating point data, which is a great advantage for real systems, the diagnostic system also performs well for regions for which it has not been trained. The present proposal allows to extend the application of multivariable control techniques already developed for this benchmark to the problem of fault tolerant control, by combining the multivariate statistical monitoring techniques here proposed.

Keywords— Quadruple Tank Process, Multivariate Statistical Monitoring, Fault Diagnosis

Resumo— A aplicação de técnicas estatísticas multivariadas tem se tornado cada vez uma alternativa vantajosa para detecção e diagnóstico de falhas dada a grande disponibilidade de dados em sistemas de automação industrial. A existência de benchmarks que reproduzam o comportamento de processos industriais contribui para o desenvolvimento de novas técnicas. Neste trabalho, o modelo de quatro tanques acoplados, proposto originalmente para o desenvolvimento de técnicas de controle multivariado, é explorado para a avaliação de técnicas de detecção de falhas recentemente desenvolvidas para processos operando em diferentes pontos de operação. As falhas usuais em processos reais são introduzidas no modelo, bem como alternativas para operar o processo em diferentes regiões. Uma metodologia é proposta para gerar dados para treinamento e teste de um sistema de diagnóstico com a capacidade de diferenciar falhas de mudanças de pontos de operação. Mesmo sendo treinado com dados de apenas um ponto de operação, o que é uma grande vantagem para sistemas reais, o sistema de diagnóstico tem bom desempenho também para regiões para as quais não foi treinado. A presente proposta permite estender a aplicação de técnicas de controle multivariável já desenvolvidas para este benchmark ao problema de controle tolerante a falhas, ao combinar a elas técnicas de monitoramento estatísticos multivariado aqui propostas.

Palavras-chave— Sistema de tanques acoplados, Monitoramento estatístico multivariado, Diagnóstico de falhas

# 1 Introdução

A grande disponibilidade de dados em sistemas de automação industrial viabiliza a aplicação de métodos para deteccão e diagnóstico de falhas. Métodos baseados em dados usando estatísticas multivariadas são muito adequados dada disponibilidade de dados e não requerer conhecimentos sobre modelos matemáticos dos processos monitorados. A análise por componentes principais(PCA) permite reduzir a dimensionalidade do grande número de variáveis nestas aplicações, além de aumentar a robustez das estatísticas de teste calculadas (L H Chiang and Braatz, 2001). Estes métodos são derivados das cartas de Shewhart, usados para monitorar variáveis de qualidade. A aplicação para o caso multivariado com variáveis que não sejam de qualidade requer maior atenção, pois a estacionariedade dos sinais monitorados não é garantida. Mudanças de ponto de operação devido a mudanças de referência, insumos, e outros fatores indica falsos alarmes nas soluções clássicas de monitoramento estatístico multivariado (MEM). Métodos tem sido propostos na literatura para atacar este problema.

Neste trabalho estas técnicas são aplicadas a um sistema de tanques acoplados, proposto originalmente na literatura para a aplicação de técnicas de controle multivariado. Sistema similares a este são comuns em processos industriais, permitindo avaliar as técnicas em situações próximas da realidade da indústria (Gambier, 1999). Avalia-se a introdução de falhas em sensores, atuadores e na estruturada planta, bem como o uso de técnicas para sua detecção e diagnóstico.

#### 2 Revisão da Literatura

Nessa seção é feita uma breve revisão teórica dos métodos e técnicas utilizados bem como uma contextualização da sua utilização no estudo de caso.

# 2.1 Análise por componentes principais e estatística $T^2$ de Hotelling

A análise por componentes principais é uma importante ferramenta para o monitoramento estatístico multivariado, reduzindo a dimensionalidade dos dados ao mesmo tempo que aumenta a robustez do cálculo da estatística usada para detecção de falhas (MacGregor and Kourti, 1995).

Para construção de um modelo PCA, um conjunto com n amostras das variáveis que caracterizam operação normal é usado para treinamento. Subtrai-se a média e calcula-se a matriz de covariância amostral S dada pela equação (1).

$$S = \frac{1}{n-1} X^T X = V \Lambda V^T + \tilde{V} \tilde{\Lambda} \tilde{V}^T \qquad (1)$$

onde V é a matriz de carregamento associada aos a maiores autovalores de S contidos na matriz  $\Lambda$ , representando a variância dos dados desejada e X é a matriz com n amostras das m variáveis.

Para cada nova amostra x das variáveis, a estatística  $T^2$  é calculada por (2)

$$T^2 = x^T V \lambda^{-1} V^T x \tag{2}$$

e comparada ao limiar dado pela distribuição F , equação (3) (L H Chiang and Braatz, 2001)

$$T_{\alpha}^{2} = \frac{a(n-1)(n+2)}{n(n-a)} F_{\alpha}(a, n-a)$$
 (3)

onde n é o número de amostras e a é o número de componentes principais.

#### 2.2 Detecção de falhas usando variáveis externas

Os métodos para monitoramento estatístico multivariado consideram em sua maioria que as variáveis monitoradas estão em estado estacionário. Esta abordagem deriva da análise univariada usando carta de Shewhart, que considerava o monitoramento de variáveis de qualidade, as quais em geral tendem a se manter próximas a valores preestabelecidos. Uma simples mudança da referência de uma malha de controle altera o valor médio de uma variável de processo monitorada, e esta mudança deve ser diferenciada de uma falha. Uma alternativa simples é o uso de múltiplos modelos PCA ((Zhao et al., 2004), (Yong et al., 2015)) detectando-se um novo ponto de operação previamente conhecido e usando o modelo PCA correspondente. A desvantagem é o treinamento de modelos para todas as regiões, podendo haver muitos modelos. Outras alternativas para monitoramento de processos com múltiplos pontos de operação podem ser encontradas em (Tan, 2011) e (Tong et al., 2013).

Assumindo que a mudança do ponto de operação se deva a variáveis conhecidas, foi proposto em (Kano et al., 2004) o uso da denominada análise externa para distinguir falhas de mudanças normais nas condições de operação.

O conjunto de dados X com m variáveis e n amostras é decomposto em (4),

$$X = [HG] \tag{4}$$

onde G é o grupo de variáveis externas e H o grupo de variáveis principais que devem ser monitoradas.

A matriz de coeficientes que relaciona os dois grupos de variáveis é obtida via mínimos quadrados por (5) e a matriz de erros, que é a parte decomposta das variáveis principais que não depende das variáveis externas, é obtida de (6)

$$C = (G^T G)^{-1} G^T H \tag{5}$$

$$E = H - GC \tag{6}$$

Os resíduos associados às variáveis principais calculados desta forma são utilizados para a detecção e o diagnóstico de falhas.

#### 2.3 Diagnóstico de falhas

O diagnóstico das falhas detectadas pode ser feito via técnicas supervisionadas ou não supervisionadas. No primeiro grupo estão os métodos de isolação de falhas que selecionam as variáveis que contribuíram para a falha (L H Chiang and Braatz, 2001), os quais não permitem em geral indicar de forma inequívoca a falha. As técnicas utilizadas neste trabalho pertencem ao segundo grupo, tratado como um problema de classificação (Patan, 2008).

Os resíduos gerados na etapa de detecção são utilizados para o diagnóstico. As falhas conhecidas são antes utilizadas para gerar os resíduos correspondentes usados no treinamento. Nesse trabalho será utilizada uma rede neural feedforward de 2 camadas.

# 3 Sistema de quatro tanques acoplados

Em (Johansson et al., 1999) foi proposto um sistema de quatro tanques interligados (Quadruple-Tank Process) com o objetivo de estudar problemas de controle multivariado usando técnicas lineares e não lineares. Suas características principais:

- É não linear.
- $\bullet\,$  As saídas são fortemente acopladas.
- Todos os estados podem ser medidos.

#### • Os estados e entradas são restritos.

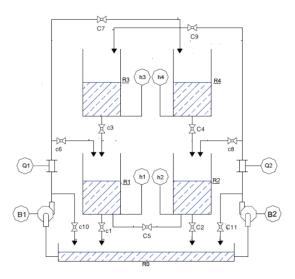
A planta consiste em quatro tanques interconectados. O objetivo é controlar o nível dos tanques inferiores a partir do acionamento das duas bombas. A abertura das válvulas afeta o controle e o acoplamento entre os tanques. Originalmente, trata-se de um sistema de duas entradas e duas saídas. Variantes deste sistema de tanques são comercializadas por empresas que desenvolvem kits educativos, de modo que os problemas avaliados via simulação podem posteriormente ser implementados em plantas piloto, gerando soluções prontamente aplicáveis na indústria.

O objetivo deste trabalho é explorar este benchmark para análise de algoritmo de detecção e diagnóstico de falhas. Um processo muito conhecido para esta finalidade é o *Tennessee Eastman Process*, proposto por (Downs and Vogel, 1993).

A vantagem da presente proposta é o uso de um processo muito comum na indústria, de fácil simulação e que pode ser construído de forma a testar os métodos com as restrições adicionais de sistemas reais. O sistema usado aqui é uma modificação da proposta original feita em (Alvarado et al., 2006).

Considera-se a presença de sensores de nível nos quatro tanques, sensores de vazão nas duas bombas, e um sistema de válvulas que permite alterar o acoplamento entre os quatro tanques. Esta nova configuração mostra-se muito adequada para explorar falhas nos equipamentos. As adaptações desta configuração para o presente trabalho são mostradas na figura 1, e o modelo proposto em (Alvarado et al., 2006) foi simulado no *MATLAB*.

Figura 1: Planta piloto



A bomba  $B_1$  leva água aos tanques  $R_1$  e  $R_4$ , sendo a vazão em cada tanque dependente das válvulas  $c_6$  e  $c_7$ . A bomba  $B_2$  leva água aos tanques

 $R_2$  e  $R_3$ , com a vazão em cada tanque dependente das válvulas  $c_8$  e  $c_9$ . As vazões das bombas  $B_1$  e  $B_2$  são medidas  $(q_1$  e  $q_2)$ . O nível de cada tanque é medido  $(h_1, h_4, h_2$  e  $h_3)$ . Há também válvulas para diminuir a vazão dos tanques superiores para os inferiores  $(c_3$  e  $c_4)$ . As válvulas  $c_{10}$  e  $c_{11}$  visam simular uma queda no rendimento das bombas  $B_1$  e  $B_2$ , retornando parte da vazão bombeada para o tanque  $R_0$ .

#### 3.1 Possíveis falhas no sistema de tanques

As falhas em um processo industrial ocorrem usualmente nos medidores, atuadores e elementos estruturais. Listamos abaixo como estas falhas podem ser introduzidas no sistema de tanques, sendo facilmente reproduzíveis em sistemas reais.

Falhas em medidores: Estas falhas se manifestam normalmente através de uma polarização que aumenta continuamente no tempo, sendo corrigida via calibração. Outra possível falha é a parada de funcionamento do medidor, sendo seu valor de medida mantido constante apesar de estar variando continuamente devido a ruídos e distúrbios. Sua simulação no sistema de tanques pode ser feita adicionando um sinal tipo rampa ao valor do medidor.

Falhas em atuadores: Os atuadores podem apresentar limitações de funcionamento ou para de responder a sinais de controle. As válvulas usadas podem entupir gradualmente devido ao depósito de sedimentos. As bombas podem ter seu desempenho reduzido devido a problemas elétricos e mecânicos. O entupimento de válvulas é simulado variando o coeficiente das válvulas  $c_1$  a  $c_9$ . As falhas nas bombas são simuladas alterando o coeficiente das válvulas  $c_{10}$  e  $c_{11}$ , de forma que simulem um maior retorno de vazão bombeado para o tanque  $R_0$ , não passando pelos medidores de vazão  $(q_1 e q_2)$ .

Falhas estruturais: As falhas típicas no sistema estudado são entupimentos e vazamentos. Estas falhas são facilmente simuladas alterando o coeficiente de válvulas de entrada ou saída de tanques.

Para exemplificar o uso do sistema de tanques para avaliar as metodologias de detecção e diagnóstico de falhas usadas, são introduzidas 3 falhas. As falhas foram implementadas com três níveis de intensidade: fraca, média e forte, visto que em um cenário realista a intensidade das falhas pode variar muito em relação aos dados usados para treinamento.

As simulações são feitas usando o modelo descrito em Alvarado (2006), com um controlador PID para controle do nível  $h_1$  atuando sobre a bomba  $B_1$ , e um controlador PID para controle do nível  $h_2$  atuando sobre a bomba  $B_2$ .

Em operação normal os controladores mantêm os níveis dos tanques constantes. Na figura 2 é mostrado o funcionamento normal com o processo operando com  $h_1=52\%, h_2=52\%, h_3=40\%, h_4=42\%, q_1=85\%, q_2=87\%.$ 

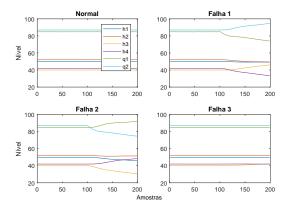
As variáveis mostradas nos gráficos estarão associadas às seguintes cores: entradas  $q_1$ (verde),  $q_2$  (azul claro) e saídas  $h_1$ (azul escuro),  $h_2$ (vermelho),  $h_3$ (amarelo) e  $h_4$ (roxo).

Falha 1: a falha na bomba  $B_1$  foi modelada por uma rampa negativa na variável  $c_{10}$  simulando a diminuição da potência da mesma com a consequentemente redução da vazão  $q_1$ . O controlador visa manter o nível dos tanques  $R_1$  e  $R_2$  continuem constantes. Para isso, aumenta-se a vazão da bomba  $B_2$ ,  $q_2$ , até o ponto em que mantém-se o nível desejado de  $h_1$ , ocasionando também um crescimento no nível do tanque  $R_3$ . Com a baixa vazão de  $q_1$  tem-se uma diminuição no nível do tanques  $R_4$  e eventualmente uma diminuição no tanque  $R_2$ , não sendo possível manter o valor especificado em regime permanente.

Falha 2: A falha na bomba  $B_2$  foi modelada similarmente a bomba  $B_1$  e tem um efeito semelhante com a falha 1 no sistema. O controle aumenta a vazão  $q_1$  para manter o nível desejado em  $h_2$ , aumentando também  $h_4$  e não sendo possível controlar os níveis dos tanques  $R_3$  e  $R_1$ .

Falha 3: O entupimento na saída do tanque  $R_3$  foi modelado como uma rampa negativa na válvula  $c_3$ , ocasionando uma diminuição de fluxo de água que se intensifica com o passar do tempo. Na ocorrência da falha 3 tem-se uma diminuição da abertura da válvula  $c_3$  fazendo o nível do tanque  $R_3$  aumentar a pressão sobre a válvula e mantendo a vazão constante, por isso não há mudanças nas demais variáveis. Esse padrão continuaria até a completa oclusão de  $c_3$ . Neste caso, o controlador atuaria aumentando a potência de  $q_2$  para aumentar o nível  $h_1$ , porém como a válvula  $c_3$  não permitiria o fluxo chegar no tanque  $R_1$  e seu nível abaixaria. Com um fluxo tão grande para o tanque  $R_3$  e a saída entupida, ele transbordaria.

Figura 2: Resposta em operação normal e com falhas

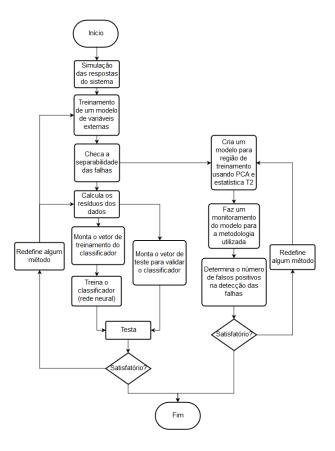


## 4 Metodologia

## 4.1 Fluxograma dos procedimentos

O fluxograma da figura 3 mostra as etapas de geração de dados via simulação, treinamento e monitoramento. São gerados conjuntos de dados para treinamento e teste em diferentes regiões de operação sob as 3 falhas descritas.

Figura 3: Fluxograma



# 4.2 Treinamento para múltiplos modos

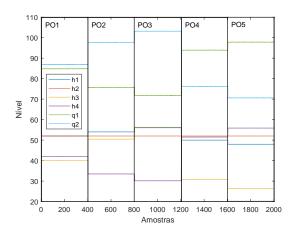
As mudanças de ponto de operação foram simuladas alterando a referência da malha de nível do tanque  $R_1$ . Em operação normal(PO1), o nível está em 50%. Nos demais pontos de operação, tem-se:  $PO2: h_1 = 52, PO3: h_1 = 54, PO4: h_1 = 48, PO5: h_1 = 46.$ 

Na figura 4 são mostradas todas as variáveis medidas para estes 5 pontos de operação. Observa-se que a mudança de referência em  $h_1$  afeta bastante as demais variáveis.

Portanto, a variável externa utilizada é a referência de nível de  $h_1$ , pois ela afeta as demais variáveis sem ser por elas afetada.

O modelo para explicar a relação da referência de nível nas demais variáveis foi buscado usando as técnicas de regressão via vetores de suporte, Generalized Regression Neural Networks, regressão por árvores e regressão polinomial de diversas

Figura 4: Resposta em operação normal em diferentes modos de operação



ordens.

Estes modelos foram usados para gerar os resíduos para diferentes conjuntos de dados, divididos em dois conjuntos:

- Conjunto de treinamento, contendo informações de operação sem que haja variação na referência do sistema, modo PO1, bem como informações nos modos PO3 e PO5, para modelar as variações positivas e negativas de referência.
- Conjunto de teste, contendo informações com variação de referência, i.e., modos de operação PO2, PO3, PO4 e PO5.

Esse conjuntos foram divididos dessa maneira pois supõe-se que seja possível modelar a variação da referência sem a necessidade de informações de todos os pontos de operação, garantindo então que a influência de uma outra mudança de modo não influencie na capacidade do modelo de detectar e diagnosticar corretamente as possíveis falhas no processo.

# 4.3 Detecção de falhas

Para fazer a detecção da ocorrência de uma falha foi criado um modelo PCA a partir dos resíduos gerados com o conjunto de dados de teste. Nesta etapa deve-se escolher o número de componentes principais utilizadas, de forma a representar grande parte da variabilidade das variáveis monitoradas. O modelo PCA em conjunto com a estatística  $T^2$  aplicados aos resíduos permite fazer o monitoramento das variáveis e detectar as falhas.

O diagnóstico é a etapa que sucede a detecção da falha, sendo usado para isto neste trabalho uma rede neural.

## 4.4 Diagnóstico das falhas

Três diferentes classificadores foram usados para fins de comparação, são esses: KNN (k-nearest neighbors algorithm), árvore de decisão e redes neurais. Os classificadores foram treinados com os resíduos rotulados das falhas. Para comparação posteriormente serão mostradas as matrizes de confusão com resultados de todos os classificadores testados.

Deseja-se diagnosticar falhas em múltiplos modos de operação, sem o esforço de treinar o sistema de diagnóstico em todos estes modos. Portanto, foram usados para treinamento dados de todas as falhas ocorridas no ponto de operação PO1, e para teste, dados de falhas ocorridas em outros pontos de operação.

Foram utilizadas para treinamento 50 amostras dos resíduos após a detecção da falha, o que se mostrou suficiente para descrever as diferenças entre cada uma delas e o sistema ser capaz de fazer o diagnóstico da mesma. Utilizou-se também para esse treinamento apenas a falha de menor intensidade, visando avaliar a capacidade de distinção das falhas com maior intensidade. Esta escolha deve-se a maior dificuldade de diagnosticar falhas de menor intensidade, cujo comportamento tem menor diferença do comportamento de normalidade.

A separabilidade das falhas é avaliada com as duas componentes principais obtidas da PCA, tanto em situação de operação normal quanto com as falhas e suas intensidades.

# 5 Aplicação e Discussão

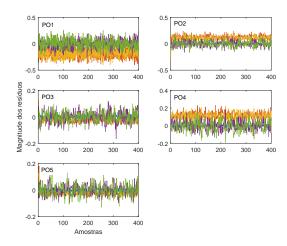
# 5.1 Análise via variáveis externas

A regressão polinomial que apresentou menores resíduos foi usando polinômios de terceira ordem. Os resíduos de cada ponto de operação podem ser vistos na figura 5. Observa-se que a variância dos resíduos difere nos 5 pontos de operação. Como esta diferença não e grande, um único modelo PCA será utilizado.

## 5.2 Detecção

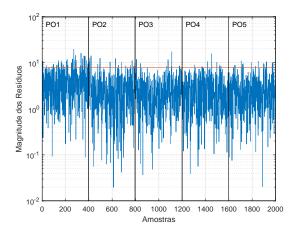
O modelo PCA é calculado concatenando os resíduos das 6 variáveis para os 5 pontos de operação. Foram utilizadas 3 componentes principais, que explicam 97.4% da variância dos resíduos. Um limiar para a estatística  $T^2$  é calculado para detecção de falhas usando a equação (3), com um intervalo de confiança de 95%. Na figura figura 6 são mostrados a estatística  $T^2$  e o limiar, apresentando 98 falsos positivos 20000 amostras, equivalente a aproximadamente 5% dos casos. Um falso positivo é descrito como o sistema indicar uma falha quando não ocorreu nenhuma, porém o algoritmo desenvolvido só chama o modelo de

Figura 5: Resíduos do treinamento por variáveis externas



diagnóstico após 5 instantes de detecção de falha, reduzindo falsos alarmes.

Figura 6: Monitoramento em operação normal em múltiplos modos



Aplicando o monitoramento ao conjunto de dados de testes e treinamento com a inclusão das falhas consegue-se observar a detecção e fazer uma medição do tempo entre a ocorrência e a detecção da falha. A figura 7 mostra o monitoramento feito para a detecção das falhas em uma das referências e a tabela 1 resume o número de instantes para detectar cada falha em cada ponto de operação e intensidade. As intensidades estão representadas na tabela na forma "pequena/média/grande".

Observa-se que foram necessários em média menos de 4 instantes para a detecção de cada uma das falhas utilizando os modelos propostos.

Figura 7: Monitoramento em operação com falhas na referência PO1

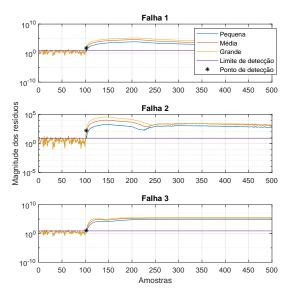


Tabela 1: Tempo de detecção das falhas em múltiplos modos e com diferentes intensidades

	Falha 1	Falha 2	Falha 3
PO1	3/2/2	2/2/2	3/3/2
PO2	4/3/3	4/3/3	5/4/4
PO3	4/3/3	4/3/3	6/5/4
PO4	4/3/3	4/3/3	5/5/4
PO5	4/3/3	5/3/3	6/5/5

## 5.3 Diagnóstico das falhas

O que garante que um modelo possa ser treinado para fazer a distinção das falhas é sua separabilidade. Para representar essa propriedade foram selecionadas as duas componentes principais do PCA que retinham a maior variância dos dados. Um gráfico de dispersão destas duas componentes foi então gerado, mostrado na figura 8.

Observa-se que a dispersão das falhas está presente em direções diferentes em relação a operação normal do sistema, evidenciando que as falhas são separáveis. Observa-se também que quanto maior a intensidade da falha mais facilmente separável ela é. Isto justificou usar apenas os dados de falhas com intensidade pequena para fazer o treinamento dos classificadores. Para o treiná-los foi usado o conjunto resíduos dos dados de falhas em modo de operação PO1, figura 9.

A técnica de rede neural escolhida foi 2-layer feedforward neural network e para comparação as técnicas de classificação de Árvore de Decisão e k-nearest neighbors (kNN), com k=2 vizinhos,

Figura 8: Separabilidade das falhas

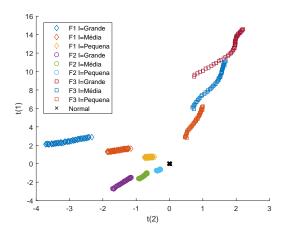
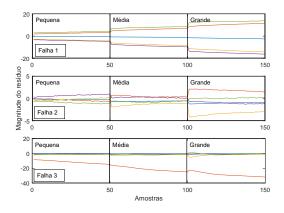


Figura 9: Resíduos usados na entrada de treinamento da Rede Neural



foram utilizadas. Após os treinamentos, os classificadores possuem como entrada uma matriz  $X_{Qx5}$  e retornam como saída  $Y_{Qx1}$  para cada instante de tempo, onde Q é o numero de amostras utilizados.

Para o conjunto de testes foram utilizado os resíduos das falhas nos outros modos de operação estudados (PO2, PO3, PO4 e PO5). Todos os resultados são mostrados pelas matrizes de confusão na tabela 2.

Pelas matrizes de confusão observam-se os resultados diagnosticados dos múltiplos modos para todos os níveis de intensidade pelos classificadores selecionados. A rede neural foi escolhida por por obter resultados superiores aos demais testados, observando-se uma taxa de acertos de 99, 1%. Para (kNN e árvore de decisões), as matrizes de confusão mostram resultados com uma boa taxa de acerto, aproximadamente 87,1% no pior caso, porém são consideravelmente menos precisos que o método de redes neurais.

É possível então concluir que que o classificador proposto é capaz de determinar, com alta confiabilidade, qual falha está acontecendo assim

Tabela 2: Matriz de confusão dos resultados de diagnóstico dos classificadores

Rede neural		Diagnosticado		
		F1	F2	F3
	F1	750	0	0
Ocorrido	F2	3	731	16
	F3	0	0	750
árvore de	Diagnosticado			
		F1	F2	F3
	F1	606	144	0
Ocorrido	F2	137	603	10
	F3	0	0	750
k-NN		Diagnosticado		
		F1	F2	F3
	F1	599	151	0
Ocorrido	F2	123	627	0
	F3	0	0	750

que é acionado pelo detector.

# 5.4 Considerações sobre o uso do sistema de tanques acoplados

Os exemplos tratados neste trabalho mostram a grande variedade de casos que podem ser tratados usando metodologias baseadas em dados para detecção e diagnóstico de falhas. A escolha das referências nas malhas de controle de nível e o uso de controladores para as malhas de vazão permitem uma enorme variedade de pontos de operação para este sistema. As relações não lineares entre as variáveis aumentam a complexidade da tarefa de obter modelos para obter resíduos dependendo dos pontos de operação em que a planta atua. As falhas podem ser introduzidas de diferentes formas e a qualquer tempo. O efeito das falhas sugeridas produz comportamentos muito variados nas variáveis monitorada (ver figura 2), podendo afetar uma ou todas variáveis. Por fim, a o problema de controle tolerante a falhas pode ser analisado na mesma planta, mesclando técnicas de controle preditivo a sistema de detecção de falhas, como feito em (Olivier and Craig, 2016), onde a técnica MPC foi mesclada a um sistema tolerante a falhas não linear com filtro de partículas.

## 6 Conclusões

Este trabalho teve como o objetivo avaliar a aplicação de técnicas de monitoramento estatístico multivariado a um sistema de tanques acoplados. Um modelo do sistema, proposto originalmente para aplicação de técnicas de controle multivariado, foi revisto para a introdução de falhas em sensores, atuadores e elementos estruturais. Para fins de exemplo, três falhas foram introduzidas com diferentes intensidades, mostrando seu efeito sobre as variáveis do processo. As facilidades para mudar a região de operação foram também discutidas, pois permitem a avaliação de recentes técnicas de detecção e diagnóstico de falhas em diferentes regiões de operação. Uma metodologia foi proposta para gerar dados de treinamento e teste para estas técnicas, de modo a explorar sua acurácia para diagnosticar corretamente falhas usando redes neurais em diferentes regiões de operação.

A facilidade para simular este processo, sua versatilidade para gerar situações bastante diversas de eventos indesejados com diferentes dinâmicas, e a existência de processos reais similares na indústria, tornam o uso deste benchmark muito adequado para a exploração de técnicas de monitoramento estatístico multivariado. Um exemplo de aplicação destas metodologias reforça as boas perspectivas de uso do sistema de tanques acoplados neste novo contexto.

## Agradecimentos

#### Referências

- Alvarado, I., Limon, D., Garcia-Gabin, W., Alamo, T. and Camacho, E. (2006). An educational plant based on the quadruple-tank process, *IFAC Proceedings Volumes* **39**(6): 82 87. 7th IFAC Symposium on Advances in Control Education.
- Downs, J. J. and Vogel, E. F. (1993). A plant-wide industrial process control problem, *Computers and Chemical Engineering* **17**(3): 245 255.
- Gambier, A. (1999). Adaptive predictive statespace control of a multivariable 3-tank system, 2.
- Johansson, K. H., Horch, A., Wijk, O. and Hansson, A. (1999). Teaching multivariable control using the quadruple-tank process, Proceedings of the 38th IEEE Conference on Decision and Control (Cat. No.99CH36304), Vol. 1, pp. 807–812 vol.1.
- Kano, M., Hasebe, S., Hashimoto, I. and Ohno, H. (2004). Evolution of multivariate statistical process control: application of independent component analysis and external analysis, Computers and Chemical Engineering 28(6): 1157 – 1166. FOCAPO 2003 Special issue.
- L H Chiang, E. L. R. and Braatz, R. D. (2001). Fault detection and diagnosis in industrial

- systems, Measurement Science and Technology 12(10): 1745.
- MacGregor, J. and Kourti, T. (1995). Statistical process control of multivariate processes, Control Engineering Practice 3(3): 403 – 414.
- Olivier, L. E. and Craig, I. K. (2016). Fault-tolerant nonlinear mpc using particle filtering, *IFAC-PapersOnLine* **49**(7): 177 182. 11th IFAC Symposium on Dynamics and Control of Process SystemsIncluding Biosystems DYCOPS-CAB 2016.
- Patan, K. (2008). Artificial neural networks for the modelling and fault diagnosis of technical processes, Springer.
- Tan, S. (2011). Multimode process monitoring based on mode identification, *Industrial and Engineering Chemistry Research* 51(1): 374 388.
- Tong, C., Palazoglu, A. and Yan, X. (2013). An adaptive multimode process monitoring strategy based on mode clustering and mode unfolding, *Journal of Process Control* **23**(10): 1497 1507.
- Yong, G., Xin, W. and Zhenlei, W. (2015). Fault detection for a class of industrial processes based on recursive multiple models, *Neuro*computing 169: 430 – 438.
- Zhao, S. J., Zhang, J. and Xu, Y. M. (2004). Monitoring of processes with multiple operating modes through multiple principle component analysis models, *Industrial and engineering chemistry research* 43(22): 7025 7035.