

Extração e seleção de características em múltiplos classificadores locais para diagnóstico de falhas em processos industriais

Gustavo B. Santi¹, Victor N. Rebli², Patrick M. Ciarelli¹,
Thomas W. Rauber², e Celso J. Munaro¹

¹ Laboratório de Controle e Instrumentação, Departamento de Engenharia Elétrica Centro Tecnológico, Universidade Federal do Espírito Santo, 29075-910 Vitória, Brazil gustavo.santi@aluno.ufes.br, munaro@ele.ufes.br, patrick.ciarelli@ufes.br

² Núcleo de Inferência e Algoritmos, Departamento de Informática Centro Tecnológico, Universidade Federal do Espírito Santo, 29075-910 Vitória, Brazil {thomas,vnrebli}@inf.ufes.br

Resumo Diversos métodos têm sido desenvolvidos ao longo dos anos para monitorar e detectar falhas em processos industriais, sendo uma delas o uso de um classificador com um conjunto de características para realizar o diagnóstico das falhas. No entanto, o uso de um único classificador para várias falhas pode tornar a tarefa mais complexa e reduzir a acurácia. Neste artigo é proposta uma abordagem que, ao invés de treinar um único classificador, utiliza previamente um processo não supervisionado para agrupar as falhas e em seguida é utilizado um classificador para cada grupo de falhas, diminuindo a complexidade dos classificadores e aumentando a acurácia. Para melhorar a qualidade dos resultados, são selecionadas, para cada grupo, as características com maior poder de discriminação entre as falhas. Um estudo de caso é realizado através de simulações sobre um simulador *benchmark* da literatura e os resultados obtidos indicam que a proposta é promissora para rotular e diagnosticar corretamente as falhas.

Keywords: Diagnóstico; seleção de características; aprendizagem de máquinas

1 Introdução

Para a boa produtividade de um processo industrial é importante detectar rapidamente problemas relacionados ao mau funcionamento de equipamentos, alteração na qualidade dos insumos e distúrbios externos ao processo. Também é necessário diagnosticar a causa de comportamentos indesejados para a sua rápida solução [13].

O uso de modelos estatísticos multivariados é particularmente atraente porque reduzem muito a dimensionalidade dos dados analisados, permitindo uma fácil representação gráfica, interpretação e tratamento de dados faltantes [9]. Dentre as técnicas existentes, a Análise por Componentes Principais (*Principal Component Analysis* – PCA) é uma das mais frequentemente utilizadas devido

à simplicidade de sua aplicação e sua elevada difusão na literatura. Além de permitir o monitoramento estatístico de processos, a metodologia também fornece uma ferramenta para diagnóstico conhecida como gráficos de contribuição, em que são identificadas as variáveis que possuíram participação na falha [2]. Outras técnicas derivadas do PCA foram propostas para diagnóstico de falha, como em [16], no qual os autores propõem uma PCA particionada (PPCA) junto com PCA tradicional para a construção de vários modelos com a intenção de examinar a mudança do processo em diferentes direções de monitoramento, de modo que a falha possa ser detectada e diagnosticada. Em [15] os autores utilizam PCA descentralizado dinâmico (DDPCA) para modelar e monitorar variáveis que alteram o comportamento da dinâmica do processo.

Quando há abundância de dados históricos de falhas, com diversos tipos de falhas conhecidas, métodos de classificação e agrupamento de dados podem ser aplicados para auxiliar no diagnóstico de falhas [7]. Recentemente, técnicas de aprendizagem de máquina têm sido incorporadas e, metodologias de aprendizado supervisionado e não supervisionado têm sido desenvolvidas baseadas em conhecimento a priori do processo estudado e que possuem excelente desempenho e precisão para classificação e diagnóstico de falhas [17].

Nesse artigo é proposta uma metodologia que une a análise estatística multivariada e a aprendizagem de máquina para o diagnóstico de falhas em processos industriais. A metodologia proposta consiste em agrupar as falhas por suas semelhanças e, para cada grupo, treinar um classificador com o conjunto de características que melhor discriminam as falhas. Essa metodologia mostrou ser mais efetiva do que treinar um único classificador para todas as falhas.

2 Análise de Componentes Principais - PCA

2.1 Monitoramento estatístico

Seja $\mathbf{X} = [\mathbf{x}_1 \cdots \mathbf{x}_n]^T \in \mathbb{R}^{n \times m}$ uma matriz com m variáveis e n observações de dados do processo em funcionamento normal caracterizando o funcionamento normal do sistema. Para o uso da PCA é necessário normalizar as variáveis de forma que tenham média zero e variância unitária. A matriz de covariância de \mathbf{X} é então aproximada pela matriz de covariância amostral:

$$\mathbf{S} \cong \frac{1}{n-1} \mathbf{X}^T \mathbf{X} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^T + \tilde{\mathbf{P}} \tilde{\mathbf{\Lambda}} \tilde{\mathbf{P}}. \quad (1)$$

Esta técnica realiza a decomposição da matriz de covariância em autovetores e autovalores, dos quais são obtidas as matrizes de carregamento dos subespaços principal e residual, $\mathbf{P} \in \mathbb{R}^{n \times \ell}$ e $\tilde{\mathbf{P}} \in \mathbb{R}^{n \times (m-\ell)}$, respectivamente, sendo ℓ o número de componentes principais retidas. A matriz $\mathbf{\Lambda}$ é diagonal e possui em seus elementos os autovalores das componentes principais selecionados organizados em ordem decrescente, enquanto os autovalores das demais componentes estão na diagonal da matriz $\tilde{\mathbf{\Lambda}}$. Em [2] os autores apresentam três estatísticas para monitoramento do processo: distribuições T^2 de Hotelling, o quadrado do

erro de predição Q e estatística combinada φ . O cálculo de cada uma dessas é realizado segundo a equação (2) e as matriz característica \mathbf{M} utilizada em para uma determinada estatística é mostrada na tabela 1.

$$\text{Estatística} = \mathbf{x}^T \mathbf{M} \mathbf{x} \quad (2)$$

Tabela 1: Matrizes características.

Estatística	\mathbf{M}	Limiar
Q	$\tilde{\mathbf{C}} = \tilde{\mathbf{P}} \tilde{\mathbf{P}}^T$	δ^2
T^2	$\mathbf{D} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^T$	t^2
φ	$\mathbf{\Phi} = \frac{\tilde{\mathbf{C}}}{\delta^2} + \frac{\mathbf{D}}{t^2}$	φ_{lim}

A cada estatística é associado um limiar de controle, sendo o cálculo dos mesmos demonstrados em [12]. O monitoramento do processo é realizado acompanhando uma ou mais estatísticas e uma falha é detectada quando ocorre a violação dos seus limiares, que usualmente são determinados com o auxílio de dados de normalidade do processo.

2.2 Gráficos de contribuição

Gráficos de contribuição são ferramentas largamente utilizadas para auxílio no diagnóstico de falhas, devido a sua simples implementação e a não necessidade de conhecimento prévio sobre o funcionamento do sistema. Eles são baseados na ideia que as variáveis com as maiores contribuições são consideradas as causadoras da falha.

Seja um conjunto de dados medidos a partir do instante t até f instantes após a detecção da j -ésima falha $\mathbf{X}^j = [\mathbf{x}_t \cdots \mathbf{x}_{t+f}]^T \in \mathbb{R}^{f \times m}$. Em [2] é apresentada uma forma de cálculo das contribuições da i -ésima variável para a falha, nos f instantes analisados, na forma:

$$\mathbf{c}_i^j = \left(\xi_i^T \mathbf{M}^{\frac{1}{2}} \mathbf{x}_k \right)^2, \quad (3)$$

sendo ξ_i a i -ésima coluna de uma matriz identidade de tamanho m representando cada variável analisada e $k = t, t + 1, \dots, t + f$. O cálculo da contribuição das m variáveis resulta na matriz de contribuições $\mathbf{C}^j \in \mathbb{R}^{f \times m}$, onde cada coluna contém a contribuição da i -ésima variável durante os f instantes de falha.

A função dos gráficos de contribuição nem sempre é indicar as variáveis com maior contribuição e sim o comportamento delas, pois falhas diferentes podem ter influências similares em uma mesma variável. Em alguns casos, processos com controle em malha fechada podem levar a diagnósticos equivocados quando analisados apenas os gráficos de contribuição, pois os controladores do processo

alteram as variáveis manipuladas para corrigir problemas, mascarando algumas vezes a real responsável pela falha [7] ao levar rapidamente as variáveis controladas de volta para suas referências.

Para evitar equívocos no diagnóstico de falhas devido à análise de apenas dados de contribuição, é proposto o uso desses dados em conjunto com classificadores treinados com falhas conhecidas. Desta forma, não somente a variável com maior contribuição é considerada, mas sim o comportamento das variáveis analisadas para uma determinada falha.

3 Metodologia proposta

A metodologia proposta usa múltiplos classificadores locais para realizar a identificação de falhas, ao invés de um único classificador global. A motivação da proposta é que um único classificador teria que ter uma complexidade maior para realizar a separação correta das diferentes falhas em um processo, enquanto que classificadores locais podem ser mais simples por atuarem com um subconjunto menor de falhas e, além disso, podem retornar diagnósticos mais precisos.

Inicialmente as falhas são agrupadas de forma não supervisionada em diferentes grupos. Observa-se que é possível uma mesma falha estar presente em mais de um grupo. Depois, é projetado para cada grupo um classificador que identificará somente as falhas presentes no grupo. Como a maioria dos grupos devem possuir somente subconjuntos das falhas, a tarefa de identificação torna-se menos complexa para os classificadores locais. Eventualmente, também é possível haver grupos com somente uma única falha, o que dispensa o uso de classificadores.

Quando uma falha for detectada, inicialmente ela será agrupada em um dos grupos previamente existentes; se no grupo houver originalmente somente um tipo de falha o diagnóstico já está feito. Caso contrário, o classificador responsável pelo grupo é aplicado sobre a nova falha e irá identificá-la. Para melhorar os resultados dos classificadores locais, para cada um deles é selecionado um subconjunto de características que melhor discriminam as falhas de um grupo.

Embora neste trabalho seja usado um conjunto de técnicas para aplicar o método, diferentes técnicas podem ser usadas, não se limitando somente às técnicas escolhidas. Nas subseções seguintes são apresentadas em mais detalhes as etapas da metodologia.

3.1 Agrupamento das falhas

Considera-se que \mathbf{X}^j contém dados da j -ésima falha, de um total de p falhas. Sobre os dados de cada matriz \mathbf{X}^j são calculadas as estatísticas apresentadas na tabela 1, utilizando as matrizes características \mathbf{M} e os limiares estatísticos obtidos previamente pelo PCA sobre dados normais do processo, e verifica-se as variáveis que contribuíram para a violação desses limiares, de acordo com [10]. Com isso, é obtida uma nova representação dos dados na qual é usado um vetor binário \mathbf{S}^j para representar as m variáveis. Esse vetor representa uma amostra da j -ésima falha, em que as variáveis que contribuíram na violação do limiar

estatístico são representados por uns e as demais por zeros. Observa-se que com uma matriz \mathbf{X}^j é obtida uma única amostra da j -ésima falha. Portanto, para serem obtidas N amostras da mesma falha, são necessários N conjuntos de dados contendo a mesma falha. De forma igual, para obter amostras de outras falhas, são necessários vários conjuntos de dados de cada uma, permitindo a criação da matriz de variáveis em falha $\mathbf{S}_F \in \mathbb{R}^{p \cdot N \times m}$, sendo $p \cdot N$ o número total de amostras da matriz, considerando que cada falha tem N amostras.

Uma vez que se tenha os dados representados na forma de amostras, é possível aplicar um algoritmo de agrupamento não supervisionado. Neste trabalho foi usado o algoritmo *k-means*, por ser uma técnica bastante difundida na literatura e simples de implementação [1]. Para o seu uso é necessário estabelecer a métrica de distância a ser usada e o número de grupos. Como as amostras têm formato binário, neste trabalho foi usada a distância de Hamming como métrica, por ser mais apropriada.

3.2 Classificadores locais

Antes de treinar e usar um classificador local para cada grupo, é extraído um conjunto de características das matrizes de contribuição. Seja \mathbf{X}^j a matriz de dados da j -ésima falha associada a um vetor binário que está contido em um grupo g . Inicialmente são calculadas as contribuições \mathbf{C}^j para a falha analisada, conforme a equação 3. Nota-se que a matriz \mathbf{C}^j tem as mesmas dimensões que \mathbf{X}^j . Em seguida os dados dessa matriz são divididos em intervalos iguais de d observações sobre o qual será extraído um conjunto de sete características de cada uma das m variáveis. Estas características são apresentadas em [4], e são: média, desvio padrão, média dos aumentos, média das reduções, aumento máximo, redução máxima e desvio padrão das diferenças. O conjunto de características extraídas de cada intervalo forma uma amostra (vetor de características) usada pelo classificador e unindo-se os vetores de características é obtida a matriz de características $\mathbf{C}_H \in \mathbb{R}^{f/d \times 7 \cdot m}$.

O novo conjunto de amostras é usado em um classificador, tanto na fase de treinamento quanto na fase de identificação. O classificador escolhido foi o *random forest*, que identifica complexas interações entre os dados; ao mesmo tempo que evita uma memorização do modelo. [3].

Os passos descritos nesta subseção são referentes somente ao grupo g . O mesmo procedimento deve ser realizado para os demais grupos, ou seja, para cada grupo é associado um classificador, com exceção dos casos em que houver somente um tipo de falha em um grupo. Nestes casos, toda amostra de agrupamento que se localizar neste grupo já é rotulada como tal falha.

3.3 Seleção de características

Em busca de melhorar os resultados obtidos pelos classificadores locais, um passo adicional é realizado na metodologia, que consiste em selecionar o subconjunto de características que discriminam melhor as falhas de um grupo.

Neste trabalho foi usada a abordagem de [18], que usa a técnica *Particle Swarm Optimization* (PSO) para a seleção de características. PSO é um algoritmo de otimização baseado em uma população de partículas (soluções) que tendem a explorar o espaço de busca, identificando a melhor solução. [8]. Na abordagem de [18] são incluídos fatores que ajudam na seleção de características. A proposta era de criar uma estratégia de inicialização de partículas cujo objetivo é absorver os benefícios dos métodos de seleção de características *forward selection* (FS) e *backward selection* (BS) [6]. O FS começa com um conjunto vazio de características e iterativamente adiciona ao conjunto de características já selecionadas aquela que obter a melhor métrica de classificação naquela iteração. O BS, por outro lado, começa com todas as características disponíveis no conjunto e iterativamente remove-as até que o desempenho da classificação cessa de melhorar. Na estratégia de inicialização proposta em [18], a maioria das partículas são inicializadas usando um pequeno conjunto de características (simulando FS), e as outras partículas são inicializadas usando um extenso conjunto de características (simulando BS). Através da interação entre as partículas, espera-se que o PSO tenha condições de pesquisar o espaço de busca de maneira mais eficiente.

Para o uso do PSO é necessário determinar a função objetivo, ou seja, aquela que se deseja minimizar ou maximizar com as soluções encontradas. Neste trabalho foi usada a métrica de acurácia como função objetivo, pois ela mede a taxa de acerto do classificador. Desta forma, cada partícula do PSO possui uma seleção de características, e essas características são usadas para treinar o classificador local. A acurácia obtida pelo classificador sobre um conjunto de amostras mede o desempenho da partícula. Por fim, para cada um dos grupos é utilizado o PSO para selecionar as características mais discriminativas.

3.4 Aplicação da metodologia para diagnóstico de falhas

Após o treinamento dos classificadores, como explicado anteriormente e ilustrado na fig. 1, sendo \mathbf{X}_N a matriz com todos os dados das falhas conhecidas e k o número de grupos, é desejado aplicar os classificadores locais treinados para realizar o diagnóstico de falhas em novos dados.




Figura 1: Diagrama do treinamento da metodologia

Uma vez detectada uma falha, são coletadas f observações das m variáveis do processo, formando a matriz de dados em falha \mathbf{X}^{new} que será usada para a realização do diagnóstico. Desta matriz de dados \mathbf{X}^{new} é calculado o vetor binário \mathbf{S}^{new} das variáveis que tiveram participação para a falha, e encontra-se o grupo ao qual a falha pertence. Calcula-se então a matriz de contribuições \mathbf{C}^{new} , de onde são extraídas as características que foram selecionadas pelo PSO para o grupo em que a falha foi agrupada. Essas características são então informadas ao classificador local que irá realizar o diagnóstico da nova falha. Esses passos são ilustrados na fig. 2.




Figura 2: Diagrama de aplicação da metodologia para diagnóstico

4 Aplicação e resultados

Nesta seção a metodologia proposta é comparada com o uso de um único classificador e também é analisado o método de seleção de características. As avaliações são realizadas em dados de um *benchmark* de um reator de tanque agitado continuamente (*Continuous Stirred-Tank Reactor* – CSTR), proposto em [5] e [14].

4.1 CSTR

O CSTR consiste na reação exotérmica de um reagente A com concentração inicial c_{A0} a temperatura T_1 com vazão F_1 . As reações que ocorrem no tanque são principalmente exotérmicas, sendo assim, torna-se necessário refrigerar o reator. Isso é realizado pela passagem de água fria através de uma jaqueta externa que troca calor com o tanque. A fig. 3 ilustra um desenho esquemático do reator e na tabela 2 estão mostradas as nove variáveis analisadas, bem como suas siglas e suas unidades.

4.2 Comparação entre classificadores locais e um classificador global

Para testar a metodologia foi criada uma base de dados contendo 100 simulações de cada uma das falhas de 3 a 18 listadas em [14], resultando numa base de dados de 1600 simulações. A partir dos dados obtidos com as simulações é calculada a matriz de variáveis em falha, que é utilizada para a criação dos grupos. Uma análise exploratória dos dados revelou um padrão de seis possíveis combinações de variáveis que possuíram influência na violação do limiar estatístico das falhas

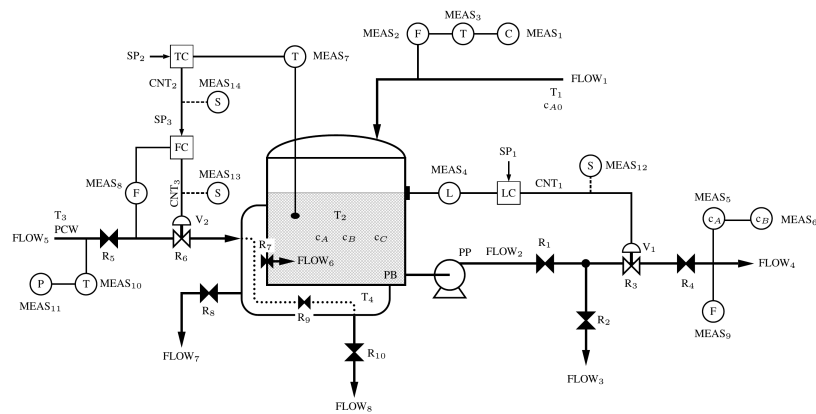


Figura 3: O modelo de CSTR definido em [5,14].

Tabela 2: Variáveis do simulador

ID	Descrição da variável	Sigla	Unidade
1	Temperatura do reator	T_2	$^{\circ}\text{C}$
2	Pressão do refrigerante	PP	Pa
3	Temperatura do reagente	T_1	$^{\circ}\text{C}$
4	Temperatura do refrigerante	T_3	$^{\circ}\text{C}$
5	Nível do reator	L	m
6	Vazão do produto	F_4	m^3/s
7	Vazão do refrigerante	F_5	m^3/s
8	Vazão do reagente	F_1	m^3/s
9	Concentração do reagente	c_{A0}	mol/m^3

analisadas. Esse valor é então selecionado como o parâmetro para o número de grupos calculados pelo *k-means*. Os resultados obtidos com o agrupamento são mostrados na tabela 3.

Tabela 3: Resultado do agrupamento das falhas

Grupo	Falhas
1	5, 6, 7, 18
2	3, 4, 8, 9, 10, 11, 14, 17
3	5, 7, 12, 18
4	15, 16
5	5, 7, 18
6	13

Observa-se que a maioria das falhas ocorreram em apenas um grupo, e que a maioria dos grupos possuem quatro falhas ou menos, com exceção do grupo 2. O grupo 6, por exemplo, possui apenas uma falha. Portanto, uma falha atribuída a este grupo será automaticamente classificada como falha 13. Nos demais grupos é aplicado o algoritmo de classificação proposto.

Para avaliar a metodologia proposta foram construídos três modelos. No modelo 1 foi aplicado um único classificador para as 16 falhas. No modelo 2 são criados classificadores para cada grupo, sendo que em cada grupo são utilizadas todas as características de todas as variáveis. No modelo 3 é criado um classificador para cada grupo, porém são utilizadas apenas as características das variáveis que tiveram participação nas falhas do grupo em questão.

Na etapa de treinamento dos modelos, 70% dos dados de contribuição em cada grupo são selecionados para treinar o classificador e os demais 30% para validação. Ao realizar a divisão dos dados, é mantida a mesma proporção de amostras de falhas presentes no grupo. Para o cálculo das contribuições foram utilizadas 40 observações após a falha e os dados foram divididos em dois segmentos de 20 observações para a extração de características.

Os resultados de acurácia obtidos pelos modelos são apresentados na tabela 4. Não são apresentadas acurácias para o grupo 6, pois como no mesmo há apenas uma falha ele não possui classificador, porém em todas as situações houve 100% de acurácia para a falha alocada nesse grupo.

Tabela 4: Acurácias dos classificadores (%)

Grupo	1	2	3	4	5	Global
Modelo 1	-	-	-	-	-	86,45
Modelo 2	90,83	78,12	97,08	100	95,56	92,31
Modelo 3	90,42	78,12	96,67	100	95,56	92,15

Analisando a tabela 4 é possível perceber que o uso do agrupamento das falhas (modelos 2 e 3) em comparação ao uso de um classificador único (modelo 1) apresenta um desempenho superior de cerca de seis por cento na acurácia global, pois a complexidade dos classificadores foi reduzida e foi permitida uma melhor generalização durante o treinamento. Comparando os modelos 2 e 3, percebe-se que o desempenho dos modelos é aproximadamente o mesmo, porém, no modelo 3 é utilizada uma quantidade menor de características por serem usadas somente as variáveis que contribuíram com a falha.

4.3 Avaliação da seleção de características

Nesta seção é analisada a aplicação da seleção de características no modelo 3, aplicando-se o PSO para identificar e selecionar as características mais relevantes (modelo 4). Durante a execução do PSO, cada partícula em cada iteração utiliza os mesmos dados de treinamento e validação utilizados no treinamento

e validação dos modelos 1, 2 e 3, sendo que o resultado obtido pela melhor partícula representa o conjunto reduzido de características encontrado pelo PSO que melhor discrimina as falhas.

Para avaliar o novo modelo, 100 novas simulações são geradas para cada falha para atuar como conjunto de teste, e os modelos 2, 3 e 4 são comparados para verificar a robustez dos modelos em novos dados. Os modelos 2 e 3 são os mesmos treinados na seção anterior, e o modelo 4 também foi treinado com os mesmos dados.

A acurácia obtida pelos modelos 2, 3 e 4 foram, respectivamente, 90% e 92% e 94,06%, demonstrando uma superioridade do modelo 4. Além disso a aplicação do PSO permitiu reduzir o número de características a serem informadas ao classificador de um total de 63 características calculadas (7 para cada uma das 9 variáveis) para seis características para os grupos 1 e 3, 7 características para o grupo 2, uma característica para o grupo 4 e cinco características para o grupo 5.

A fig. 4 ilustra a matriz de confusão obtida pelo modelo 4, na qual pode-se observar que o maior número de diagnósticos errados ocorreu no grupo 2 entre as falhas 8 e 11, ou seja, para essas falhas o classificador utilizado não é sempre capaz de diferenciá-las corretamente.

Acurácia de: 94.06%

Falha 18	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	97	
Falha 17	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0
Falha 11	0	0	0	0	0	0	29	7	3	80	0	0	0	0	0	0	0	0	0	0
Falha 10	0	0	0	0	0	0	3	0	92	0	0	0	0	0	0	0	0	0	0	0
Falha 9	0	0	0	0	0	0	4	90	0	7	0	0	0	0	0	0	0	0	0	0
Falha 8	0	0	0	0	0	0	64	3	5	13	0	0	0	0	0	0	0	0	0	0
Falha 7	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	3
Falha 6	0	0	0	10	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Falha 5	0	0	89	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Falha 4	0	100	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Falha 3	97	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	Falha 3	Falha 4	Falha 5	Falha 6	Falha 7	Falha 8	Falha 9	Falha 10	Falha 11	Falha 12	Falha 13	Falha 14	Falha 15	Falha 16	Falha 17	Falha 18				

Falha Simulada

Figura 4: Matriz de confusão

Para investigar a razão disso é aplicado sobre as características extraídas o *t-Distributed Stochastic Neighbor Embedding* (t-SNE), uma técnica para redução de dimensionalidade para a visualização de dados com alta dimensão [11], per-

mitindo a visualização dos dados em duas dimensões. Na fig. 5 são mostradas apenas as falhas 8 e 11, ilustrando o motivo de o classificador local possuir dificuldade em discriminar especialmente essas falhas.




Figura 5: t-SNE com duas dimensões para as falhas 8 e 11

5 Conclusão

Neste trabalho foi proposta uma metodologia que realiza o diagnóstico de falhas utilizando agrupamento de dados, extração e seleção de características, múltiplos classificadores e banco de dados com falhas previamente rotuladas. Nos casos estudados, a metodologia obteve elevado desempenho global diagnosticando corretamente até 94,06% das falhas. No entanto, em casos onde as falhas analisadas possuem influência semelhante na resposta do sistema, os classificadores treinados não são capazes de separar totalmente as falhas, gerando diagnósticos incorretos entre essas falhas.

Possíveis aperfeiçoamentos na metodologia incluem o uso de diferentes métodos de cálculo de contribuição das variáveis; a definição e a extração de outras características e a realização do ajuste de parâmetros referentes a extração de características e do classificador.

Agradecimentos

Este trabalho recebeu o apoio da Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) e da Vale S.A., sob o termo de cooperação número

29501.412.19434.18122015 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Referências

1. Aggarwal, C.C., Reddy, C.K.: Data clustering: algorithms and applications. CRC press (2013)
2. Alcalá, C., Qin, S.J.: Reconstruction-based contribution for process monitoring. IFAC Proceedings Volumes 41(2), 7889–7894 (2008)
3. Breiman, L., Friedman, J., Stone, C.J., Olshen, R.A.: Classification and regression trees. CRC press (1984)
4. Dang, T.N., Wilkinson, L.: Timeexplorer: Similarity search time series by their signatures. In: Int. Symposium on Visual Computing. pp. 280–289. Springer (2013)
5. Finch, F.E.: Automated fault diagnosis of chemical process plants using model-based reasoning. Ph.D. thesis, Massachusetts Institute of Technology, Dept. of Chemical Engineering (1989), <http://hdl.handle.net/1721.1/14194>
6. Guyon, I., Elisseeff, A.: An introduction to variable and feature selection. Journal of machine learning research 3(Mar), 1157–1182 (2003)
7. Joe Qin, S.: Statistical process monitoring: basics and beyond. Journal of chemometrics 17(8-9), 480–502 (2003)
8. Kennedy, J.: Particle swarm optimization. In: Encyclopedia of machine learning, pp. 760–766. Springer (2011)
9. Kourti, T.: Process analysis and abnormal situation detection: from theory to practice. IEEE control systems 22(5), 10–25 (2002)
10. Liu, J., Chen, D.S.: Fault isolation using modified contribution plots. Computers & Chemical Engineering 61, 9–19 (2014)
11. Maaten, L.v.d., Hinton, G.: Visualizing data using t-sne. Journal of Machine Learning Research 9(Nov), 2579–2605 (2008)
12. MacGregor, J.F., Kourti, T.: Statistical process control of multivariate processes. Control Engineering Practice 3(3), 403–414 (1995)
13. Mnassri, B., Ouladsine, M., et al.: Reconstruction-based contribution approaches for improved fault diagnosis using principal component analysis. Journal of Process Control 33, 60–76 (2015)
14. Oyeleye, O.O.: Qualitative modeling of continuous chemical processes and applications to fault diagnosis. Ph.D. thesis, Massachusetts Institute of Technology, Dept. of Chemical Engineering (1990), <http://hdl.handle.net/1721.1/14281>
15. Tong, C., Lan, T., Shi, X.: Fault detection and diagnosis of dynamic processes using weighted dynamic decentralized pca approach. Chemometrics and Intelligent Laboratory Systems 161, 34–42 (2017)
16. Wang, G., Liu, J., Li, Y., Zhang, C.: Fault diagnosis of chemical processes based on partitioning pca and variable reasoning strategy. Chinese Journal of Chemical Engineering 24(7), 869–880 (2016)
17. Widodo, A., Yang, B.S.: Support vector machine in machine condition monitoring and fault diagnosis. Mechanical systems and signal proc. 21(6), 2560–2574 (2007)
18. Xue, B., Zhang, M., Browne, W.N.: Particle swarm optimisation for feature selection in classification: Novel initialisation and updating mechanisms. Applied Soft Computing 18, 261–276 (2014)