
Classificador Baseado na Teoria de Conjuntos Aproximados Aplicado ao Diagnóstico de Falhas em Motores de Indução Trifásicos monitorados através de Sinais Acústicos, Elétricos e de Vibração

F. O. Assunção
G. L. Torres

E. L. Bonaldi
A.C. Bertolini

L. E. Borges da Silva
L. E. L. de Oliveira

Universidade Federal de Itajubá - UNIFEI
Av. BPS, 1303. Pinheirinho
CEP 37500-903 – Itajubá - MG

Resumo: As técnicas de processamento digital de sinais e inteligência artificial têm sido largamente aplicadas à manutenção preditiva de motores de indução trifásicos. Muitas são as técnicas de análise da condição do motor, dentre elas destacam-se a análise de vibração, de corrente e a análise acústica. Os artigos técnicos publicados normalmente abordam cada técnica separadamente. Este artigo tem como objetivo propor um classificador robusto baseado na teoria de conjuntos aproximados para diagnóstico de falhas em MIT através da análise de sinais acústicos, elétricos e de vibração. Os sinais analisados são oriundos de (Payne et alii, 2001) e foram submetidos a uma etapa de processamento digital, cujo resultado foi submetido ao algoritmo de classificação de falhas. Os resultados obtidos permitem avaliar as vantagens e desvantagens de cada análise (acústica, vibração e corrente) além de fornecer as características indispensáveis de cada uma para uma classificação robusta de uma falha potencial. Desta forma os autores esperam contribuir para uma tomada de decisão com relação a que tipo de técnica se utilizar e/ou qual o mais vantajoso é o emprego conjunto das análises. E ainda, fornecer um conjunto mínimo de atributos para serem analisados de forma a se obter uma classificação segura e confiável.

Palavras Chaves: Manutenção preditiva, motores de indução trifásicos, classificador robusto, processamento de sinais e conjuntos aproximados.

Abstract: The Digital Signal Processing and the Artificial Intelligence techniques have been widely applied to predictive maintenance of three-phase induction motor. There are so many techniques of analysis of motor conditions. The highlights are vibration, current and acoustics analysis. The publications normally treat each technique separately. This objective of this paper is the proposal of a robust classifier based on Rough Sets theory applied to induction motors diagnosis through acoustics, electrical and vibration signals. The analyzed signals come from (Payne et alii, 2001) and they were submitted to a digital processing phase and the results have feed the fault classification algorithm. The obtained results let us evaluate the advantages and disadvantages of each analysis (acoustics, vibration and current), besides the results present the indispensable characteristics of each one in order to provide a robust classification for a potential failure. This way the authors expect to contribute to make a decision about the best

technique to be used and/or how important is the used of all techniques together. And more, providing a minimum group of attributes to be analyzed in order to get a reliable and safe classification.

Keywords: Predictive maintenance, induction motors, robust classification, signal processing and rough sets.

1 INTRODUÇÃO

As técnicas de manutenção preditiva de motores de indução trifásicos têm sido largamente utilizadas na indústria. Dentre todas as técnicas, as que merecem maior destaque são as técnicas não invasivas como: análise acústica, de vibração e assinatura da corrente elétrica.

Atualmente, a análise de vibração é largamente utilizada na detecção de falhas em máquinas rotativas. Apesar das razões que justificam a grande difusão da técnica, existem determinados problemas associados a mesma que estimulam o estudo e aplicação de outras técnicas. Um dos focos de problema da análise de vibração se encontra no processo de aquisição do sinal de vibração pelos acelerômetros. Os principais problemas são: (i) o sinal de vibração colhido por um acelerômetro é um sinal local e em alguns casos não produzirá informação no outro extremo da máquina; (ii) a análise depende da orientação do transdutor; (iii) o efeito do caminho de transmissão do sinal que pode atenuar as componentes características de falha.

Considerando estes e outros problemas, torna-se interessante a análise de outras técnicas. Alguns pesquisadores tem destacado os benefícios da utilização de microfones em máquinas alternativas sobre a utilização de acelerômetros. As vantagens principais são: (i) a instalação e localização de um único microfone para monitoração acústica é mais fácil que a instalação de acelerômetros. Os requisitos são a instalação próxima a máquina e o microfone deve estar direcionado diretamente para a mesma; (ii) o microfone é um sensor remoto, sem contato, o que elimina preocupações com a faixa de temperatura de contato do dispositivo e problema do sensor se desprender da máquina; (iii) o método acústico, em muitos casos, pode ser usado como um método de detecção global de falhas, eliminando a necessidade do emprego de vários sensores de vibração em diferentes pontos da máquina.

No caso específico de motores de indução, cujos aspectos construtivos são relativamente simples e se contrapõem à complexidade de seu princípio de funcionamento e à relação entre parâmetros predominantemente elétricos e mecânicos, têm-se condições de monitoração intrinsecamente complicadas e por isso merecem um estudo mais detalhado. O estudo relatado neste artigo compara a aplicação de três técnicas de análise e submete as informações oriundas de cada uma delas a um classificador de falhas que possibilitará importantes conclusões no diagnóstico de falhas em MIT.

Este artigo tem como objetivo propor um classificador robusto baseado na teoria de conjuntos aproximados para diagnóstico de falhas em MIT através da análise de sinais acústicos, elétricos e de vibração. Os sinais analisados são oriundos de (Payne et alii, 2001) e foram submetidos a uma etapa de processamento digital, cujo resultado foi submetido ao algoritmo de classificação de falhas. Os resultados obtidos permitem avaliar as vantagens e desvantagens de cada análise (acústica, vibração e corrente) além de fornecer as características indispensáveis de cada uma para uma classificação robusta de uma falha potencial. Desta forma os autores esperam contribuir para uma tomada de decisão com relação a que tipo de técnica se utilizar e/ou quão vantajoso é o emprego conjunto das análises. E ainda, fornecer um conjunto mínimo de atributos para serem analisados de forma a se obter uma classificação segura e confiável.

2 O SISTEMA EXPERIMENTAL

O motor de indução foi ensaiado pela equipe do Doutor Bradley Payne do Strategic Research Center da Rolls Royce no Reino Unido. A montagem utilizada compõem-se de um MIT acoplado a um gerador DC conectado a um banco de carga elétrica que dissipa a energia elétrica em forma de calor.

Existem cinco acelerômetros instalados, três transdutores de efeito hall e um microfone. A aquisição dos sinais foi feita simultaneamente com uma frequência de amostragem de 25,6 KHz, 160.000 amostras por canal e ainda foi realizado a média de cinco aquisições.

2.1 O processamento do sinal

O processamento dos sinais fornecidos pelo grupo anteriormente citado foi feito no Matlab 6 utilizando-se ferramentas matemáticas de processamento digital, como: reamostragem digital, filtros digitais, janelamento, FFT, cálculo das frequências de interesse e curvas de tendência.

2.2 As Falhas Monitoradas

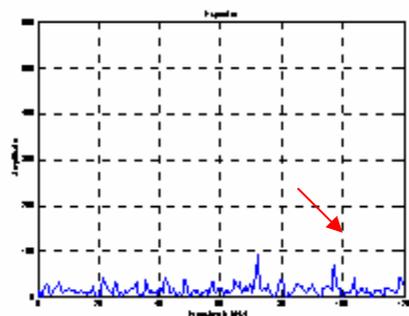
Foram analisados dois tipos de falhas: desequilíbrio de tensão em uma das fases e barras quebradas. A cada falha foram atribuídos dois graus de severidade e cinco níveis de carga: vazio, 25%, 50%, 75% de carga e plena carga.

2.2.1 Desequilíbrio de tensão de uma fase

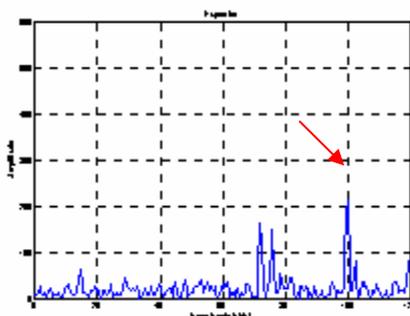
Na prática, o desequilíbrio de fase pode ocorrer devido à saída de um transformador ou de um banco de capacitores, má distribuição de cargas monofásicas, perda de conexões elétricas e falta ou incompleta transposição de linha de distribuição.

Nos ensaios realizados foram induzidos 20V e 40V de desequilíbrio, os espectros dos sinais com a falha foram comparados com a operação normal do motor.

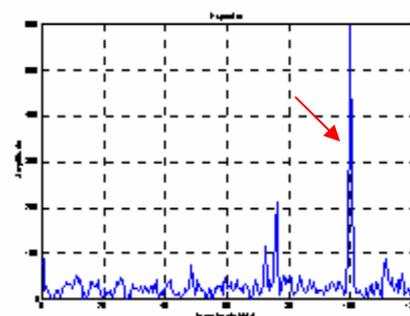
A título de ilustração são apresentados os espectros dos testes efetuados com plena carga. Os espectros apresentados são do acelerômetro posicionado no *drive end*, do microfone e do hall instalado na fase B.



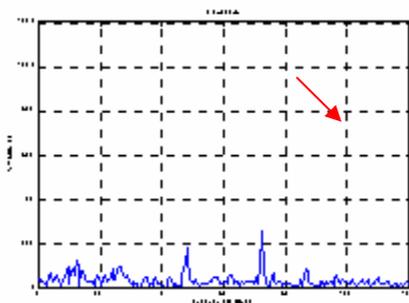
Vibração – Motor Saudável



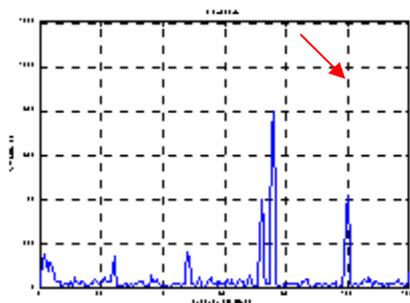
Vibração – Desequilíbrio de Tensão 20V



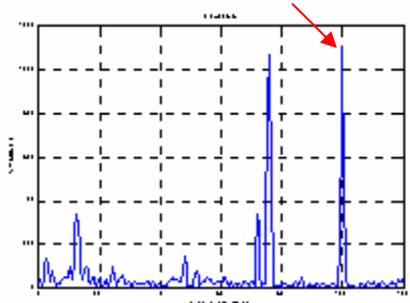
Vibração – Desequilíbrio de Tensão 40V



Acústico – Motor Saudável



Acústico – Desequilíbrio de Tensão 20V



Acústico – Desequilíbrio de Tensão 40V

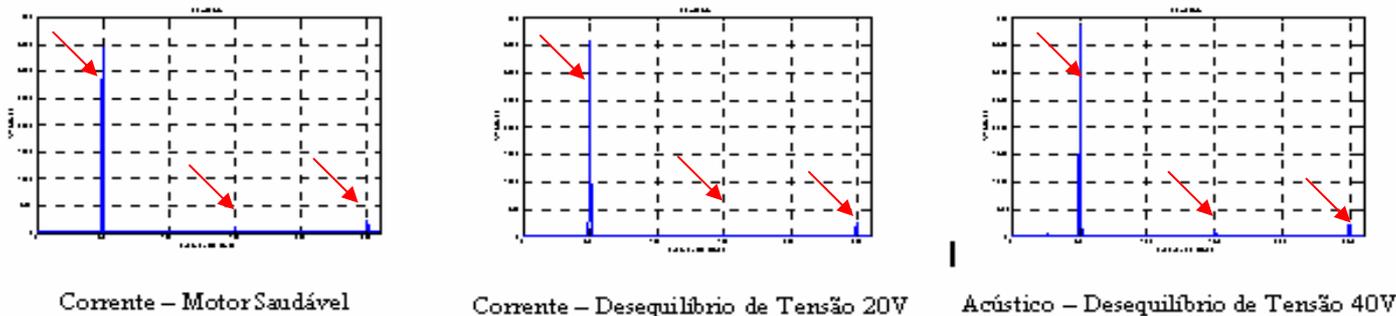


Figura 2: Espectro de Vibração, Acústica e Corrente para falha de desbalanceamento de tensão

Como pode ser observado na fig. 2, a componente de interesse nos espectros de vibração e acústica que apresenta um aumento considerável de magnitude é a de 100 Hz (2 vezes a frequência de alimentação), sendo que a análise acústica respondeu de forma mais evidenciada que a análise de vibração.

Já as componentes de interesse no espectro de corrente são: 50, 150 e 250 Hz, sendo que a componente de 150 Hz tem sua amplitude sempre acrescida e a de 250 Hz reduzida. Para um diagnóstico eficaz de desequilíbrio de tensão através da assinatura da corrente torna-se necessário a análise de pelo menos duas fases, já que não se pode prever onde ocorrerá o desequilíbrio de tensão (Benbouzid et alii, 1999).

2.2.2 Quebra de Barras

A falha de quebra de barras em MIT é muito comum em muitas aplicações industriais. As elevadas correntes de partida, quando a ventilação é baixa, resultam em um stress térmico e mecânico que levam à quebra de barras, que é comumente detectada pela presença de bandas laterais de duas vezes a frequência de escorregamento em torno da velocidade de rotação no espectro de vibração e em torno da frequência de alimentação no espectro de corrente (Thomson. W. T. et alii, 2001). A seguir, são apresentados os espectros dos testes efetuados com plena carga para a falha em questão.

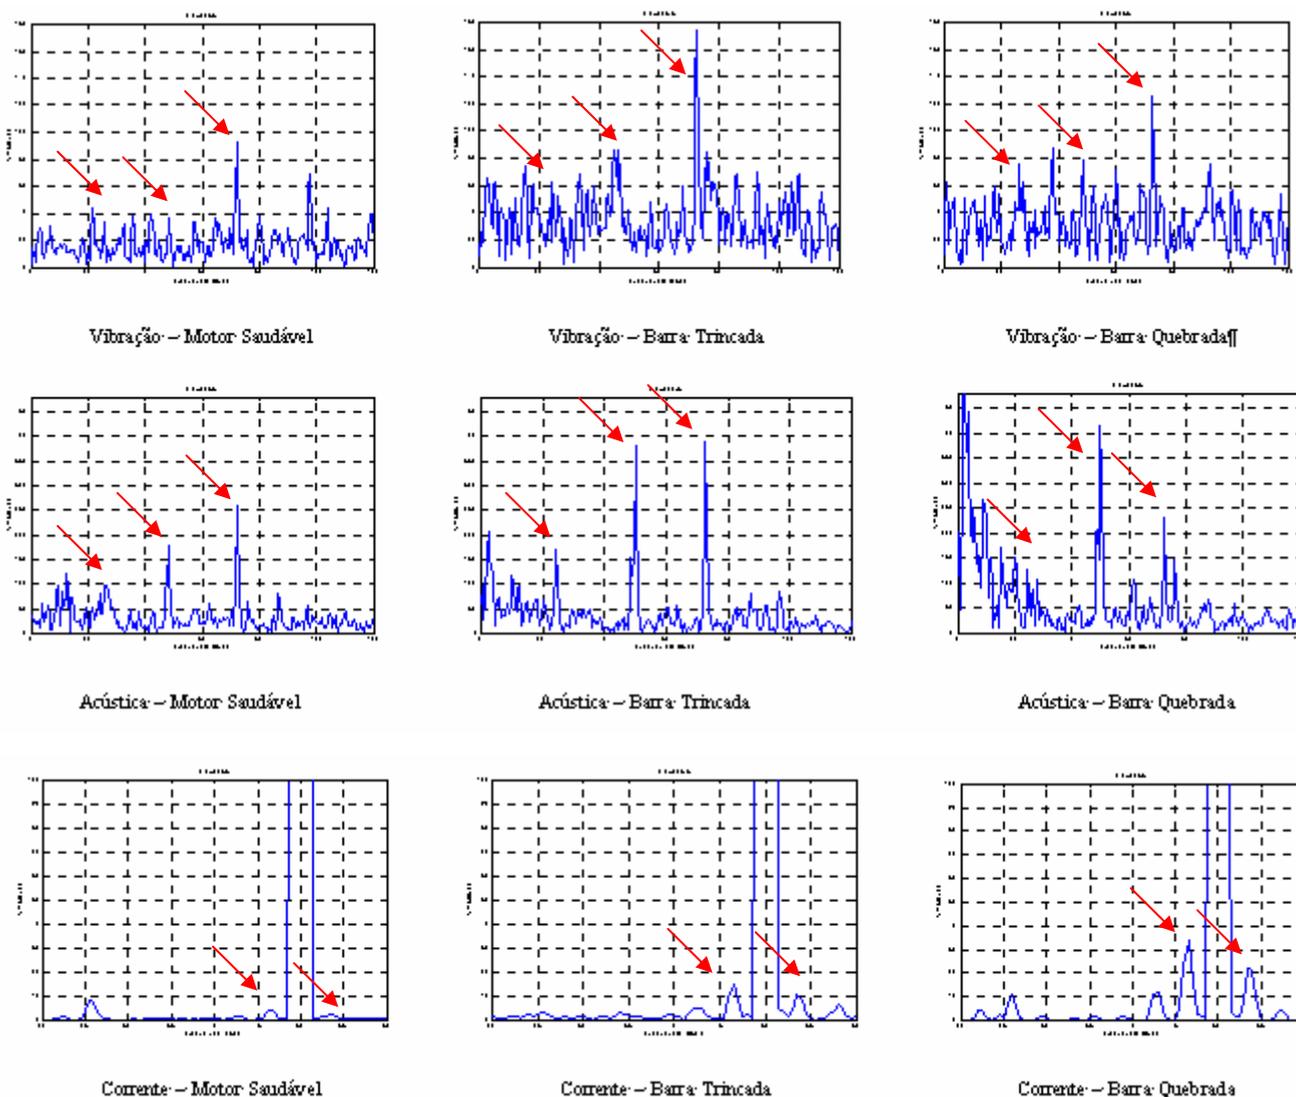


Figura 3: Espectro de Vibração, Acústica e Corrente para falha de barras quebradas

Como pode ser observado da figura 3, o diagnóstico de quebra de barras através dos espectros de vibração e acústica é feito através das seguintes componentes características: 24, 48, 72 e 96 Hz (frequência de rotação em Hz, 2°, 3° e 4° harmônicos).

Já a análise em corrente inspeciona as compontes em torno da fundamental e a própria componente fundamental, isto é, $f+2fs$, $f-2fs$, e f . No espectro em questão: 46, 50 e 54 Hz.

Para este caso de barras quebradas a análise de corrente mostrou-se mais adequada, uma vez que as componentes de vibração e acústica apresentaram oscilações mediante o aumento de severidade da falha.

3 O CLASSIFICADOR

O classificador proposto baseia-se na teoria de conjuntos aproximados. A principal idéia é transformar um conjunto de exemplos em um conjunto de regras que representa o estado operacional de um motor de indução. As entradas (atributos) deste classificador são os sinais processados de vibração, acústica e corrente.

Desta forma, o algoritmo de classificação propõe-se a receber uma massa grande de dados oriundos dos sinais processados e reduzir essa massa de dados de modo a se obter um conjunto reduzido que mantenha a mesma classificação indutiva da massa de dados iniciais. Ou seja, serão mantido apenas as informações essenciais e indispensáveis a classificação, gerando-se assim um conjunto de regras que terá como saída o tipo de falha e seu grau de severidade.

A partir dos resultados gerados pelo classificador poder-se-á concluir quais informações de qual sinal são determinantes para uma classificação robusta dos dados.

3.1 A Teoria de Conjuntos Aproximados

3.1.1 Sistema de Informação

Um sistema de informação pode ser definido como uma 4-upla $K=(U,R,V,\rho)$, onde U é um conjunto finito de objetos, R é um conjunto finito de atributos (vibração, corrente, acústica), V é o domínio de cada atributo de R e ρ é a função de informação que define a seguinte aplicação: $\rho: U \times R \rightarrow V$, isto é, os exemplos.

O conceito de sistema de informação não é exclusivo da teoria de conjuntos aproximados e tem sido amplamente utilizado em teoria de informação (Bonaldi et alii, 2002).

3.1.2 Aproximação de Conjuntos

Como algumas categorias (qualquer $X \subseteq U$) não podem ser expressas exatamente em uma base de conhecimento, utilizam-se as idéias de aproximação de um conjunto por outro conjunto. Essa característica é de extrema importância, pois uma das maiores contribuições da teoria de conjuntos aproximados é transformar, automaticamente, dados em conhecimento.

Seja uma base de conhecimento $K=(U,R)$. Com cada subconjunto $X \subseteq U$ e uma relação de equivalência $R \in \text{IND}(K)$ (indiscernibilidade de K , ou seja, a interseção de todas as relações de equivalência que pertencem a K) associa-se dois subconjuntos:

$$\underline{RX} = U \{Y \in U / R : Y \subseteq X\} \Rightarrow \text{Aproximação inferior}$$

$$\overline{RX} = U \{Y \in U / R : Y \cap X \neq \emptyset\} \Rightarrow \text{Aproximação superior}$$

Estes dois conjuntos podem ser entendidos da seguinte forma: \underline{RX} é o conjunto de todos os elementos de U que, com certeza, podem ser classificados como elementos de X na base R . \overline{RX} é o conjunto de dos elementos de U que tem possibilidade de serem classificados como elementos de X empregando-se o conhecimento R . E $BN_R(X)$ é o conjunto de elementos que não podem ser classificados nem em X e nem em $\neg X$ (complemento de X).

Estes dois conjuntos definem três regiões de interesse (figura 4): região R -positiva de X ($POS_R(X)$), região R -negativa de X ($NEG_R(X)$) e região de fronteira ($BN_R(X)$). Sendo:

$$POS_R(X) = \underline{RX}, \quad NEG_R(X) = U - \overline{RX} \quad \text{e}$$

$$BN_R(X) = \overline{RX} - \underline{RX}$$

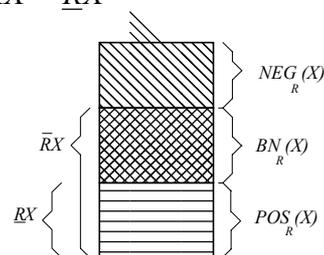


Figura 4: Regiões de interesse

Com o objetivo de se caracterizar numericamente a imprecisão de um conjunto, defini-se uma medida de precisão chamada de cardinalidade:

$$\alpha_R(X) = \frac{\text{Card } \underline{RX}}{\text{Card } \overline{RX}}$$

A imprecisão do conjunto se deve à existência da região de fronteira. Quanto maior esta região, menor a precisão do conjunto.

3.1.3 Conceitos de Reduct e Core

Os conceitos de *reduct* e *core* são extremamente importantes na redução da base de conhecimento. Seja \mathbf{R} uma família de relações de equivalência. O reducto de \mathbf{R} ($\text{RED}(\mathbf{R})$) é definido como um conjunto reduzido de relações que mantêm a mesma classificação indutiva de \mathbf{R} . Já o *core* é o conjunto de relações indispensáveis que caracterizam \mathbf{R} . (Pawlak, Z., 1991)

3.1.4 Redução da Base de Conhecimento

Um dos métodos mais comuns para se extrair conhecimento de um especialista é por exemplos. A idéia por traz da redução da base de conhecimento é a simplificação deste conjunto de exemplos. Isso pode ser executado através do algoritmo descrito na seção seguinte.

3.2 O Algoritmo

O algoritmo implementado no software proposto é baseado fundamentalmente nas ferramentas matemáticas mostradas na seção anterior sobre teoria de conjuntos aproximados. Dividido em sete passos, o algoritmo trabalha, de forma estrutural, em

etapas, varrendo linhas e colunas em cada passo em busca de informações relevantes da massa de dados, as quais são de fundamental importância para a redução do conjunto de dados original.

Dentro dos passos mencionados, podemos evidenciar certas funções, ou melhor, certos desenvolvimentos que merecem uma atenção especial. No procedimento do primeiro passo, a tabela de dados original é transformada em uma tabela de faixas definida pelo usuário. Essas faixas têm como função tornar os valores contínuos em valores discretos de forma a criar níveis de comparação entre os valores.

No segundo e terceiro passos é feita uma verificação de igualdade entre linhas e entre colunas com o objetivo de retirar possíveis exemplos iguais (linhas) e atributos iguais (colunas).

Então, no quarto passo, o algoritmo entra na fundamentação matemática: este passo tem a finalidade de encontrar todos os redutos do conjunto de dados vindo dos passos anteriores. Esses redutos são subconjuntos especiais do conjunto de dados entregue ao quarto passo e carregam todas as informações contidas na massa de dados inicial. De maneira simplificada, o procedimento do algoritmo no quarto passo é trabalhar com combinações dos atributos visando encontrar atributos dispensáveis para a classificação.

No quinto passo, a tabela formada por algum dos redutos encontrados no quarto passo ou todos, conforme a escolha do usuário, é trabalhada novamente de modo a se computar o *core*. Esse passo procede determinando-se as relações mais genéricas de cada exemplo, ou seja, aquelas relações que dependem de um número menor de atributos, logicamente mantendo a integridade das informações contida no conjunto original.

No sexto passo, a tabela gerada pelo quarto passo (Redutos) e a tabela gerada no quinto passo (Core) são combinadas. A

combinação é feita comparando-se os mesmos exemplos das tabelas. Os atributos da tabela do Core ficam fixos e então os atributos restantes da tabela de Redutos são combinados em grupos ou individualmente com esse atributos fixos, formando sub-exemplos. Esses sub-exemplos formam a tabela do sexto passo.

Finalmente, no sétimo e último passo, a tabela gerada no sexto passo sofre possíveis fusões de sub-exemplos. Os sub-exemplos mais genéricos muitas vezes englobam os sub-exemplos menos genéricos que são eliminados, formando a tabela final. Ainda nesse passo, o algoritmo gera as regras linguísticas a partir da tabela final.

4 DESCRIÇÃO DO PROBLEMA

A proposta do artigo é transformar um conjunto de exemplos originado dos sinais processados em um conjunto de regras que especifique o tipo de falha (neste artigo: desequilíbrio de tensão e barra quebrada) e represente o estado operacional de um motor de indução (Normal, severidade 1, severidade 2).

O estado operacional do motor de indução e o modo de falha dependem de informações obtidas dos sinais colhidos do motor (vibração, acústica e corrente). Obviamente uma análise mais abrangente, ou seja, com uma grande gama de motores, exigiria um número maior de parâmetros de entrada como características do motor (potência nominal, tensão, corrente e velocidade) e características gerais do processo relacionados ao tipo de carga e condições de instalação, carga e do ambiente onde o motor está inserido.

A tabela seguinte apresenta o conjunto de exemplos, relacionando os diferentes atributos já classificados em faixas (L – Low, M – Medium, H – High magnitude).

Tabela 1: Massa de dados Original

Reg	f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16	Torque	Falha	Gravidade
1	L	L	L	L	L	L	L	L	L	H	M	L	M	M	L	L	0	Normal	Normal
2	M	H	L	L	L	L	M	L	M	H	M	M	L	M	M	L	0	BQ	Half
3	L	H	L	L	L	L	H	L	H	H	M	M	H	H	H	L	0	BQ	Full
4	L	L	L	L	L	L	L	L	L	H	M	L	M	L	M	L	25	Normal	Normal
5	M	L	L	L	L	L	M	L	M	H	M	H	L	M	L	L	25	BQ	Half
6	L	M	L	L	L	L	H	L	H	H	M	M	L	H	M	L	25	BQ	Full
7	L	L	L	L	L	L	L	L	L	H	M	M	L	M	L	L	50	Normal	Normal
8	M	L	L	L	L	L	M	L	M	H	M	M	L	L	M	L	50	BQ	Half
9	L	M	L	M	L	M	H	L	H	H	M	M	L	M	M	L	50	BQ	Full
10	L	L	L	L	L	L	L	L	L	H	M	M	L	L	L	L	75	Normal	Normal
11	L	L	M	L	L	L	M	L	M	H	M	H	L	H	H	L	75	BQ	Half
12	M	M	L	H	L	M	H	L	H	H	M	L	H	H	M	L	75	BQ	Full
13	L	L	L	L	L	L	L	L	L	H	M	L	L	M	L	L	100	Normal	Normal
14	M	L	H	H	L	L	M	L	M	H	M	H	M	H	H	L	100	BQ	Half
15	L	M	L	L	L	M	H	L	H	H	M	L	H	H	H	L	100	BQ	Full
16	L	L	H	L	M	M	L	M	L	L	M	L	L	H	L	M	0	PI	20V
17	L	M	H	L	H	H	L	H	L	M	M	M	L	M	L	H	0	PI	40V
18	L	M	H	L	M	M	L	M	L	L	M	H	L	H	L	M	25	PI	20V
19	L	M	H	L	H	H	L	H	L	M	M	M	L	H	L	H	25	PI	40V
20	L	M	H	L	M	M	L	M	L	L	M	M	L	H	L	M	50	PI	20V
21	M	L	H	L	H	H	L	H	L	M	M	M	H	M	L	H	50	PI	40V
22	L	L	H	L	M	M	L	M	L	L	M	M	L	H	L	M	75	PI	20V
23	L	M	H	L	H	H	L	H	L	M	M	M	H	M	L	H	75	PI	40V
24	M	L	H	L	M	M	L	M	L	L	M	M	M	H	L	M	100	PI	20V
25	L	L	H	L	H	H	L	H	L	M	M	M	H	M	L	H	100	PI	40V

Essa massa original de dados foi criada a partir da seleção dos seguintes sensores: microfone, acelerômetro B e sensor hall na fase B. A razão para a escolha desses sensores justifica-se em função da melhor resposta às falhas apresentadas pelos mesmos.

Seja cada um dos atributos de entrada:

F1 a F5: 24, 48, 72, 96 e 100 Hz para a análise acústica;

F6 a F11: 26, 46, 50, 54, 150 e 250 Hz para a análise de corrente;

F12 a F16: 24, 48, 72, 96 e 100 Hz para a análise de vibração; e Torque.

E ainda os atributos de saída: Falha e Gravidade.

O conjunto reduzido e as regras de controle foram geradas pelo software baseado no algoritmo descrito na seção 3.2. De acordo com a proposta do artigo, os resultados devem levar as seguintes conclusões: avaliar as vantagens e desvantagens de cada análise (acústica, vibração e corrente) além de fornecer as características indispensáveis de cada análise para uma classificação robusta de uma falha potencial.

5 RESULTADOS

A tabela II apresenta o conjunto reduzido baseado na escolha do reduto F5, F9.

Tabela 2: Conjunto reduzido

Reg	f5	f7	Falha	Gravidade
1	L	L	Normal	Normal
2	-	M	BQ	Half
3	-	H	BQ	Full
4	M	-	PI	20V
5	H	-	PI	40V

Ou seja, a análise na frequência característica de 100 Hz no espectro acústico e a componente de 46 Hz no espectro de corrente são suficientes para classificar a condição saudável do motor, e os dois tipos de falha estudados com seus respectivos graus de severidade.

As regras de controle são dadas por:

Se f5=L e f7=L então Falha = Normal e Gravidade = Normal

Se f7=M então Falha = BQ e Gravidade = H

Se f7=H então Falha = BQ e Gravidade = F

Se f5=M então Falha = PI e Gravidade = 20V

Se f5=H então Falha = PI e Gravidade = 40V

É importante ressaltar a existência de outros redutos. A escolha adequada do reduto baseia-se no quão simples é obter informações de cada sensor.

No exemplo em questão, os outros redutos possíveis e de maior viabilidade são: (F9, F16), (F9, F10), (F8, F9), (F7, F16), (F7, F10), (F7, F8), (F6, F9), (F6, F7), (F5, F9).

6 CONCLUSÕES

No que diz respeito à escolha das análises (vibração, corrente e acústica) para o diagnóstico das falhas em questão, tem-se a partir dos resultados obtidos que uma monitoração através da aplicação conjunta das três análises é desnecessária.

A análise acústica apresentou a melhor resposta para a falha de desequilíbrio de tensão. Enquanto que a análise do espectro da assinatura da corrente se mostrou mais indicada para detecção de barras quebradas.

Contudo não se recomenda a utilização cega da análise acústica, ao mesmo passo que destaca-se a capacidade de detecção de faltas pela análise da corrente. Dentre as vantagens da análise da corrente destacam-se: aquisição do sinal em painéis de alimentação não sendo necessário o acesso à máquina e excelente resposta a uma variedade de falhas.

O classificador proposto representou de forma extremamente satisfatória o conhecimento do especialista, além de fornecer os conjuntos mínimos de atributos capazes de diagnosticar os tipos de falhas estudados.

Outra importante contribuição do classificador é a seleção das frequências de interesse que realmente contribuem para o diagnóstico de falha, ou seja, tem-se a definição de qual técnica se empregar e qual frequência com suas respectivas magnitudes se observar.

Os autores ressaltam a necessidade de se alimentar o classificador com um número maior de falhas e de exemplos para se obter um conjunto de regras bastante abrangente.

REFERÊNCIA BIBLIOGRÁFICA

- Payne, B. S, Ball, A. D, Gu, F, Li, W. (2000). A Head-to-Head Assessment of the Relative Fault Detection and Diagnosis Capabilities of Conventional Vibration and Airborne Acoustic Monitoring. Comadem 2000.
- Benbouzid, M. E. H, Vieira, M. and Theys, C (1999). Induction Motor's Faults Detection and Localization Using Stator Current Advanced Signal Processing Techniques. *IEEE Transactions on Power Electronics*, Vol 14, NO. 1, pp 14-22
- Bonaldi, E. L., Borges da Silva, L. E., Lambert-Torres, G. and Oliveira, L. E. L (2002). A Rough Sets Based Classifier for Induction Motor Fault Diagnosis. WSEAS 2002.
- Pawlak, Z. (1991). Reduction of Knowledge. In R.; Lowen (Ed.), *Rough Sets – Theoretical Aspects of Reasoning About Data*, 1st ed. Kluwer Academic Publishers.
- Thomson, W. T. and Fenger M (2001). Current Signature Analysis to Detect Induction Motor Faults. *IEEE Industry Applications Magazine*, July/August 2001.