
DETECÇÃO DE FALHAS EM ESTRUTURAS INTELIGENTES USANDO OTIMIZAÇÃO POR NUVEM DE PARTÍCULAS: FUNDAMENTOS E ESTUDO DE CASOS

Adriano Tebaldi*
atebaldi@tecumseh.com.br

Leandro dos Santos Coelho†
leandro.coelho@pucpr.br

Vicente Lopes Junior*
vicente@dem.feis.unesp.br

*Universidade Estadual Paulista - UNESP - Departamento de Engenharia Mecânica
Av. Brasil Centro, 56, CEP 15.385.000, Ilha Solteira, SP, Brasil

†Grupo Produtrônica - Programa de Pós-Graduação em Engenharia de Produção e Sistemas
PUCPR / CCET / PPGEPS / LAS - Laboratório de Automação e Sistemas, Centro de Ciências Exatas e de Tecnologia
Pontifícia Universidade Católica do Paraná, Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil

RESUMO

Os materiais piezelétricos são denominados de “materiais inteligentes” e pertencem a uma classe de dielétricos que exibem deformação significativa em resposta a aplicação de um campo elétrico. Estes materiais, também, produzem uma polarização dielétrica, ou seja, um campo elétrico em resposta a deformação no material. Esta dupla propriedade exibida pelos materiais piezelétricos torna extremamente vantajosa a aplicação destes materiais para sistemas de controle e para localização e caracterização de falhas estruturais. Neste artigo, a caracterização de falhas estruturais é realizada em dois passos. Em uma primeira etapa é utilizado o método da impedância elétrica para se determinar a região do dano e em uma segunda etapa se utiliza um método de otimização para quantificar a severidade das falhas. Identificação de falhas pertence ao grupo de problemas inversos, e portanto, não há solução única. A metodologia híbrida proposta se beneficia da técnica de impedância elétrica para localizar as regiões de danos e, assim, diminuir o número de variáveis envolvidas

no processo de otimização. O procedimento é validado através de diferentes abordagens de otimização por nuvem de partículas, que é uma técnica da inteligência coletiva, usando operadores com geração de números aleatórios baseados em distribuições Gaussiana e de Cauchy.

PALAVRAS-CHAVE: sensor e atuador piezelétrico, impedância elétrica, inteligência coletiva, nuvem de partículas, otimização de sistemas, detecção de falhas.

ABSTRACT

Piezoelectric materials exhibit significant deformation in response to an applied electric field, as well as generating an electrical charge in response to mechanical strain. Control designs and characterization of structural damage can take advantage of these dual properties. In this paper, the identification of damage is realized in two steps. The first uses the electric impedance technique in order to determine the location of the damage, and the second uses an optimization method to quantify the severity of the damage. Damage identification is an inverse problem, and has no unique solution. The hybrid approach proposed in this paper takes advantage of the electric impedance technique to localize the damaged

Artigo submetido em 01/08/2005

1a. Revisão em 24/05/2006

2a. Revisão em 05/09/2006

Aceito sob recomendação do Editor Associado

Prof. Ivan Nunes Da Silva

regions with accuracy. This information permits a decrease in the number of variables involved in the process, which is a goal for any optimization technique. The procedure is validated through different particle swarm optimization approaches using an operator with random numbers based on Gaussian and Cauchy distributions.

KEYWORDS: piezoelectric sensor and actuator, smart structure, electric impedance, swarm intelligence, particle swarm optimization, system optimization, fault detection.

1 INTRODUÇÃO

A manutenção preditiva de máquinas e equipamentos vem encontrando aceitação crescente na indústria. Manutenção preditiva consiste basicamente em monitorar parâmetros que caracterizam a condição de estruturas ou máquinas de forma a poder detectar, prever a época provável de ocorrência, e se possível, diagnosticar o tipo de falha para que se possa planejar a operação de manutenção na ocasião e de forma conveniente (Tebaldi, 2004).

As falhas ocorridas em equipamentos e estruturas podem ser devidas a atrito, fadiga, impacto, crescimento de trinca ou alguma outra razão. Para um adequado funcionamento do sistema, a falha deve ser localizada e reparada, se possível. O problema de detecção de falhas está compreendido em localizar, quantificar e estimar a vida útil restante. O local onde a falha está situada pode ter um efeito catastrófico na estrutura. Um monitoramento periódico das condições da estrutura é necessário para avaliar a integridade estrutural. Devido aos avanços nos equipamentos de processamento de sinal, a técnica de detecção de falhas tem evoluído significativamente nas últimas décadas. Os métodos de detecção de falhas podem ser classificados em dois grupos (Kabeya, 1998): métodos baseados em modelos matemáticos ou quantitativos e métodos qualitativos (não necessitam de modelo) (Chen e Patton, 1993).

O diagnóstico de falhas é um processo de avaliação de danos que pode ser pensado de duas maneiras: (i) monitoramento das mudanças de condição e, se necessário, parar a operação do equipamento antes de piorar as condições de operação; e (ii) garantir que o dano iniciado não se estenda para uma situação de risco. As técnicas de obtenção de (i) estão melhores definidas que as de (ii).

Uma importante técnica de monitoramento de estruturas é a técnica da impedância elétrica. A concepção básica desta técnica é o uso de altas frequências de vibrações, as quais excitam modos locais da estrutura. Isto permite a identificação de falhas incipientes. Esta metodologia é baseada na utilização de sensores/atuadores piezoelétricos, os quais fornecem medidas diretamente relacionadas com a impedância mecânica

da estrutura. As medidas de impedância elétrica são, geralmente, realizadas em altas frequências, maiores que 20 kHz. O pequeno comprimento de onda nessas frequências permite a detecção de pequenas mudanças na integridade estrutural. A técnica de monitoramento da condição da estrutura baseada na impedância elétrica é um método promissor de avaliação não-destrutiva.

O monitoramento da saúde estrutural (*structural health monitoring*) tem sido definido na literatura como aquisição, validação e análise de dados técnicos para facilitar as decisões no gerenciamento do número de ciclos de vida útil. O desafio que vem agregando pesquisadores é fornecer informações quantitativas dos danos presentes na estrutura. Para isto técnicas de otimização computacional (Doebbling *et al.*, 1998), redes neurais artificiais (Kaminski, 1997; Lopes Jr. *et al.*, 2000; Patton *et al.*, 2000) e algoritmos evolutivos (Friswell *et al.*, 1998; He *et al.*, 2001; Simões e Steffen, 2002; Tebaldi *et al.*, 2003; Tebaldi *et al.*, 2005) têm sido utilizados.

Neste contexto, alguns trabalhos recentes devem ser comentados. Xu *et al.* (2004) e Yang *et al.* (2005) descreveram uma técnica de monitoramento da saúde estrutural usando uma abordagem de otimização de programação evolutiva híbrida com método de avaliação não-destrutiva baseado em impedância. Os resultados apresentados demonstraram que o método proposto é eficiente em localizar e quantificar falhas em uma barra e também em uma placa. Tseng e Wang (2005) apresentaram uma técnica de identificação de danos estruturais baseada no método da impedância e usando sensores piezoelétricos. Os resultados foram promissores para um estudo de caso considerando uma barra com sensores. Marwala e Chakraverty (2006) utilizaram redes neurais auto-associativas combinadas com algoritmos genéticos para classificação de falhas em diversas estruturas cilíndricas. Os resultados de classificação apresentaram um desempenho entre 91 e 96% de classificações corretas.

O prognóstico de danos, que é a previsão em tempo real da vida útil restante do sistema, é um desafio atual que poderá alterar a concepção desta área. Este assunto é abordado com detalhes em Inman *et al.* (2005).

Dentre as técnicas emergentes da inteligência computacional que podem ser utilizadas para quantificar as falhas estruturais, pode-se citar as abordagens da inteligência coletiva. A inteligência coletiva (*swarm intelligence*) apresenta características bio-inspiradas de população e evolução similares aos algoritmos evolutivos (ou evolucionários), contudo, diferencia-se por enfatizar o comportamento de cooperação entre grupos de membros. A inteligência coletiva é utilizada para resolver problemas de otimização e cooperação de agentes inteligentes em problemas de otimização, tais como em eletromagnetismo (Robinson e Samii, 2004), planejamento

de sistemas elétricos (Kannan *et al.*, 2004), otimização de forma (Fourie e Groenwold, 2002), robótica coletiva (Liu e Passino, 2004) e controle cooperativo e/ou descentralizado (Baras *et al.*, 2003). A inteligência coletiva é inspirada na natureza, no fato de que a interação entre os diversos membros de um determinado grupo de seres vivos contribui com as suas próprias experiências para o grupo, tornando-o mais forte perante os outros. Os representantes mais conhecidos da inteligência coletiva em problemas de otimização são abordagens de colônia de formigas (Dorigo e Di Caro, 1999), nuvem ou bando de partículas (Kennedy e Eberhart, 2001), colônia de bactérias (Müller *et al.*, 2002) e sistema imunológico artificial (de Castro, 2001).

Neste trabalho são abordadas concepções de projeto de nuvem de partículas (*particle swarm optimization*, PSO) para quantificar as falhas em estruturas inteligentes. Abordagens de PSO para identificação de falhas podem ser utilizadas com maior sucesso se combinadas com a técnica da impedância elétrica. Esta abordagem híbrida é desenvolvida neste trabalho. A técnica de impedância elétrica é adotada para detectar com exatidão a região da falha, pois utiliza altas faixas de frequência, que excitam os modos locais de vibração da estrutura. Se a região da falha é conhecida, o número de parâmetros a serem adotados no processo de otimização pode ser reduzido, assim o algoritmo terá maior chance de convergir para a solução ótima, ou seja, detectar a severidade da falha. Em síntese, este trabalho focaliza a caracterização das falhas em estruturas englobando duas etapas. Na primeira etapa é utilizado o método da impedância elétrica para detectar se existe falha e, em caso positivo qual a região que ela se encontra. Na segunda etapa se utiliza nuvem de partículas para quantificar a severidade falha.

O artigo é organizado da seguinte forma. Na seção 2, alguns conceitos e características vinculados a impedância elétrica são apresentados e discutidos. As abordagens de PSO utilizadas para quantificar a falha são descritas em detalhes na seção 3. Na seção 4 é abordada a metodologia de análise. A análise dos resultados obtidos e as conclusões são apresentadas nas seções 5 e 6, respectivamente.

2 DETECÇÃO DE FALHAS

As estruturas ou sistemas mecânicos, às vezes, são submetidos a grandes esforços, os quais podem levar a uma deterioração das condições originais de trabalho. Estes danos podem ser devidos a fadiga, impacto, evolução de trincas ou algum outro motivo e causam incômodos como, por exemplo, o aumento das vibrações. A necessidade de monitorar e reparar estruturas tem originado diferentes técnicas de detecção de falhas. As primeiras investigações em detecção de falhas, a partir de dados de vibrações, foram publicadas bem antes do estabelecimento de análise modal experimental como uma

técnica popular e prática. Uma revisão geral dos métodos de detecção de falhas baseados em dados de vibrações foi apresentada por Friswell e Penny (1997). Foram abordados métodos que utilizam três tipos básicos de dados para medidas de vibrações dinâmicas: domínio do tempo, domínio da frequência e domínio modal. Doebling *et al.* (1998) realizaram uma revisão dos métodos de detecção, localização e caracterização de falhas em estruturas e sistemas mecânicos a partir da análise de medidas da resposta de vibração.

O problema de detecção de falhas é classificado como um problema inverso e consiste em determinar as causas tendo como referência os efeitos. Em problemas inversos os parâmetros de falha (comprimento e/ou localização) podem ser calculados através da variação da frequência natural. Entretanto, os problemas diretos consistem na determinação da solução a partir da completa descrição das causas (Tebaldi, 2004).

Neste contexto, na subseção a seguir são apresentados alguns conceitos de materiais piezelétricos e a técnica de detecção de falhas baseada em impedância elétrica.

2.1 Detecção de falhas baseada na técnica de impedância elétrica

Embora existam diversas definições para o termo inteligente (*smart*), a comunidade de engenharia tem adotado o termo de estruturas inteligentes (*smart structures*) desde o início da década 90 para descrever estruturas ou componentes estruturais com habilidades especiais e, que não são encontradas em materiais/estruturas convencionais.

A ciência de estruturas inteligentes é recente e nesta conjuntura podemos ter uma visão desta tecnologia como uma oportunidade para resultados em longo prazo, ou podemos examinar os impactos que as estruturas inteligentes terão na habilidade do sistema para exibir adaptação em curto prazo. O estudo da tecnologia de estruturas inteligentes é importante devido ao potencial demonstrado para estruturas convencionais em várias aplicações de controle ativo (Clark *et al.*, 1998), controle adaptativo (Silcox *et al.*, 1992) e automonitoramento de condições ou estruturas (Lopes Jr *et al.*, 2000).

Usualmente, emprega-se o termo de sistemas de materiais inteligentes a aqueles compostos de materiais piezelétricos, eletro-resistivo e magneto-resistivo, fluidos e sólidos eletro-reológico, ligas de memória de forma, ou fibras óticas. As propriedades de alguns destes materiais são conhecidas há longo tempo, como por exemplo, o efeito piezelétrico que foi descrito pela primeira vez em 1880 por Pierre e Jacques Curie.

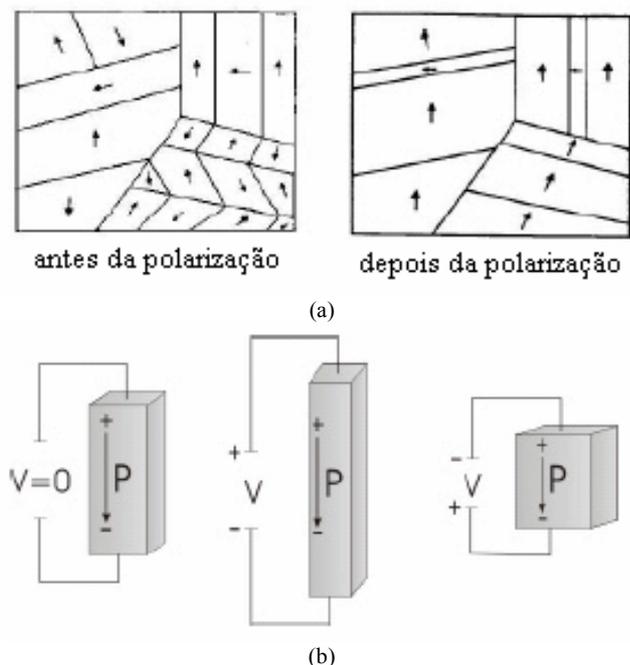


Figura 1: (a) Alinhamento dos cristais após a polarização; (b) efeito piezoelectrico.

A incorporação destes materiais como sensores e/ou atuadores em sistemas inteligentes é ainda recente e intensa investigação matemática e experimental é fundamental para a correta aplicação e utilização desta tecnologia.

Os materiais piezoelectricos, abordados neste trabalho, são os materiais mais utilizados em sistemas adaptativos (Banks *et al.*, 1996). Eles possuem a propriedade de sofrer polarização (surgimento de cargas elétricas) quando são deformados por esforços mecânicos externos (efeito piezoelectrico direto). Inversamente estes materiais têm sua forma alterada quando seus dipolos se alinham espontaneamente sob ação de um campo elétrico externo, causando deformação da estrutura cristalina (efeito piezoelectrico inverso). Em outras palavras: quando uma tensão elétrica é aplicada na mesma direção da polarização, o material alonga na direção polar e ocorre uma contração transversal. Quando a tensão elétrica é aplicada oposta à direção de polarização, o material contrai na direção polar e expande na direção transversal. Este efeito pode ser observado na figura 1.

O efeito piezoelectrico inverso é explorado na construção de atuadores, ao passo que o efeito direto é utilizado na concepção de sensores. No primeiro caso, os elementos piezoelectricos, geralmente dispostos sob forma de placas finas, são colados rigidamente na estrutura elástica. A aplicação de tensão elétrica ao material piezoelectrico gera deformações que são transferidas para a estrutura, provocando nesta o sur-

gimento de deformações mecânicas que, por sua vez, ocasionam variações nas características estáticas e dinâmicas (rigidez e frequências naturais de vibração, por exemplo). No segundo caso, os elementos piezoelectricos, geralmente dispostos sob a forma de placas ou películas finas, podem ser colados na superfície da estrutura, ou embutidos, e recebem destas as deformações mecânicas geradas por vibrações e/ou carregamentos externos. Estas deformações provocam o surgimento de cargas elétricas no material piezoelectrico, os quais constituem o sinal de saída do sensor.

A característica que torna extremamente vantajoso o uso dos materiais piezoelectricos é a possibilidade de construção de sensores e atuadores distribuídos ao longo de superfícies relativamente amplas, o que tem importantes implicações no tocante a sensibilidade dos sensores, a capacidade de aplicação de cargas dos atuadores e a potência requerida na atuação.

Diversos tipos de materiais, naturais e sintéticos, exibem propriedades piezoelectricas. Dentre eles, pode-se citar:

- *Cerâmicas piezoelectricas.* Em particular, as cerâmicas PZT (Titanato Zirconato de Chumbo), têm sido extensivamente utilizadas como elementos atuadores distribuídos, aplicados sob a forma de placas, com espessuras típicas da ordem de 0,1 a 0,2 mm;
- *Polímeros piezoelectricos.* O PVDF (Fluorido de Polivinilideno) tem tido larga utilização como sensores distribuídos, aplicados sob a forma de filmes finos, com espessura típica da ordem de 40 a 120 μm .

Esta seção descreve a técnica em que o atuador e sensor são combinados num simples elemento piezoelectrico chamado auto-sensor-atuador. O auto-sensor-atuador tem um número de propriedades desejáveis, não facilmente obtidos com sensores e atuadores separados (Inman, 1990). O atuador é integrado na estrutura e a tensão, deformação, campo elétrico e deslocamento elétrico, dentro do material piezoelectrico podem ser completamente descritos por um par de equações eletromecânicas.

As propriedades piezoelectricas são definidas utilizando-se três eixos de direções, sendo duas destas direções isotrópicas (mesmas propriedades em todos os pontos destas direções) e a outra é associada com a direção de polarização, que sofre o efeito piezoelectrico, conforme apresentado na figura 2. Os sensores e atuadores piezoelectricos podem ser criados pela polarização de material apropriado através da aplicação de um campo elétrico a altas temperaturas. A polarização tem efeito de alinhar parcialmente os eixos polares para se obter um alinhamento macroscópico que resulte no acoplamento eletro-mecânico. Como resultado deste acoplamento, o ma-

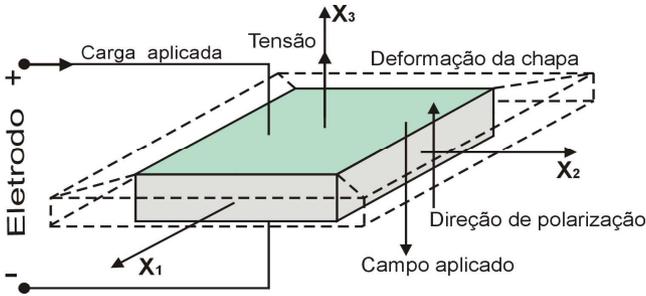


Figura 2: Direções dos eixos para materiais piezelétricos.

material piezelétrico se deforma em resposta a aplicação de um campo elétrico, dando ao material a propriedade de atuador. A capacidade de sensor do material é obtida através do efeito inverso, no qual as tensões mecânicas no material causam uma rotação parcialmente alinhada nos dipolos para gerar um campo elétrico.

Os elementos piezelétricos apresentam histerese não linear para elevados níveis de excitação, no entanto, para aplicações estruturais comuns podem ser aproximadas para lineares. Existem vários pares de equações eletromecânicas e a escolha depende do problema. Usando a notação padrão IEEE 176-1987, a tensão, a deformação e o deslocamento elétrico de um material piezelétrico podem ser descritos pelas equações (1) e (2). As letras nos colchetes indicam as unidades das variáveis no Sistema Internacional de Unidades, com Newton (N), metro (m), tensão (V) e Coulomb (C), (Clark *et al.*, 1998).

$$\{D\} = [e]^T \{S\} + [\varepsilon^S] \{E\} \quad (\text{efeito direto}) \quad (1)$$

$$\{T\} = [C^E] \{S\} - [e] \{E\} \quad (\text{efeito inverso}) \quad (2)$$

onde o expoente ()^S significa que os valores são medidos para deformação constante e o expoente ()^E significa que os valores são medidos para um campo elétrico constante, {T} é o tensor de tensão [N/m²], {D} é o vetor de deslocamento elétrico [C/m²], {S} é o tensor deformação [m/m], {E} é o campo elétrico [V/m = N/C], [C^E] é o tensor de elasticidade para campo elétrico constante [N/m²], [e] é o tensor de permissividade dielétrica [N.m/V.m² = C/m²] e [ε^S] é o tensor dielétrico para deformação mecânica constante [N.m/V².m].

Se cada elemento da matriz constante de material piezelétrico, [e], é designado por e_{ij} onde i corresponde às linhas, e j às colunas da matriz, então e_{ij} corresponde à tensão desenvolvida na j -ésima direção devido a um campo elétrico aplicado na i -ésima direção. As constantes piezelétricas de

tensão podem ser obtidas a partir das constantes da deformação, usando as equações constitutivas lineares opcionais:

$$\{S\} = [s^E] \{T\} + [d] \{E\} \quad (3)$$

$$\{D\} = [d]^T \{T\} + [\varepsilon^T] \{E\} \quad (4)$$

onde [ε^T] é o tensor dielétrico para tensão constante e [d] é uma matriz de constantes piezelétrica. A equação (3) é denominada de equação do atuador e a equação (4), de equação do sensor. A equação de movimento para um PZT vibrando na direção y , pode ser expressa como:

$$\rho \frac{\partial^2 v}{\partial t^2} = \bar{Y}_{22}^E \frac{\partial^2 v}{\partial y^2} \quad (5)$$

onde v é o deslocamento na direção y , \bar{Y}_{22}^E é o módulo de elasticidade complexo do PZT e ρ é a densidade do PZT. Separando o deslocamento nos domínios do tempo e espacial e aplicando as condições de contorno, a equação acima pode ser escrita como,

$$v = \bar{v} e^{i\omega t} = (A \sin(k.y) + B \cos(k.y)) e^{i\omega t} \quad (6)$$

$$k = \omega^2 \frac{\rho}{\bar{Y}_{22}^E} \quad (7)$$

onde ω é uma excitação harmônica constante. O deslocamento do atuador PZT, a deformação, o campo de tensão e o campo de deslocamento elétrico podem então ser determinados (Ayres, 1996). O fluxo de corrente no PZT é a taxa de tempo da carga elétrica total entre os dois eletrodos, podendo ser expressa como:

$$I = \iint_{\sigma} i\omega D_3 d\sigma \quad (8)$$

onde σ é a área do eletrodo e D_3 o deslocamento na direção do eixo z (x_3). A admitância, inverso da impedância, é $Y = I/V$ e após algumas substituições, para um PZT retangular, conforme mostrado na figura 2, pode ser encontrada como (Sun, 1996):

$$Y(\omega) = i\omega \frac{w_A l_A}{h_A} \left[\varepsilon_{33}^T - (d_{32})^2 \bar{Y}_{22}^E + \frac{Z_A(\omega)}{Z_S(\omega) + Z_A(\omega)} (d_{32})^2 \bar{Y}_{22}^E \frac{\tan(k.l_A)}{k.l_A} \right] \quad (9)$$

onde Z_A é a impedância mecânica do atuador ao longo da direção y , Z_S é a impedância mecânica da estrutura e w_A , L_A , h_A são a largura, o comprimento e a espessura do elemento PZT, respectivamente.

Uma das vantagens de elementos piezelétricos para aplicações em problemas de controle e localização de falhas resulta na relativa insensibilidade destes materiais quando utilizados abaixo da temperatura de Curie. A variação no tensor de deformação piezelétrico para um material piezocerâmico sob a ação de carga constante é menor que 12% para temperaturas até 120°C. Devido ao fato de as deformações sofridas pelo material estarem relacionadas com o valor do campo elétrico a ser introduzido, a estabilidade para a temperatura é crucial em aplicações de controle e detecção de falhas, pois erros provenientes de variações térmicas acarretarão erros na magnitude do controle e poderão fornecer informações errôneas no caso de monitoramento de defeitos estruturais.

A baixa sensibilidade à temperatura dos piezelétricos é uma vantagem sobre os elementos eletro-resistivos, pois estes são altamente dependentes da temperatura. Uma segunda vantagem dos piezelétricos está em sua flexibilidade em uma variedade de aplicações, isto é parcialmente devido a diversidade de materiais que possuem propriedades piezelétricas. Entre os materiais piezelétricos mais utilizados estão os piezocerâmicos e os piezopolímeros, dos quais os PZTs e os PVDFs são respectivos exemplos.

Devido à natureza cerâmica, os PZTs possuem boa rigidez e freqüentemente excede a da estrutura base, o que resulta em uma excelente conversão da energia elétrica em energia mecânica. Isto torna estes elementos eficientes atuadores para uma grande variedade de aplicações. Materiais piezocerâmicos são efetivos sobre uma larga faixa de freqüência, e a dupla propriedade exibida por estes materiais (*self-sensing actuators*, Dosch *et al.*, 1992) torna extremamente vantajosa sua aplicação para sistemas de controle e de localização de falhas.

Embora vantajosos em muitas aplicações, os piezocerâmicos apresentam dificuldade em assumir moldes com formas complexas devido a alta fragilidade. Alternativamente, os filmes PVDF têm consistência de uma folha plástica e podem ser colados em praticamente qualquer geometria, tem alta sensibilidade e precisão nas medidas e são, portanto, utilizados, principalmente, como sensores. A aplicação direta dos filmes PVDF como atuadores tem sido limitada, pois exibem coeficientes de acoplamento eletromecânico mais baixos que os PZT. No entanto, a resistência dielétrica dos filmes PVDF é maior que a do PZT e eles podem ser expostos a maiores campos elétricos.

O coeficiente de acoplamento eletromecânico garante a conversão efetiva de energia em um sistema de interação linear.

Neste trabalho, o coeficiente de acoplamento eletromecânico (freqüentemente denominado fator de acoplamento) do transdutor piezelétrico é considerado. Para se determinar o coeficiente de acoplamento, a informação da orientação do cristal e o arranjo de entrada e saída são requeridos, em outras palavras, o coeficiente é definido para o respectivo modo de vibração no limite estático. O coeficiente de acoplamento k é medido em percentagem para a maioria dos casos, porém ele tem maior significado quando utilizado ao quadrado, k^2 , o qual corresponde à razão de energia.

Por apresentarem um comportamento aproximadamente linear sob baixos campos elétricos, relativos a insensibilidade à variação de temperatura e flexibilidade como sensores e atuadores, os elementos piezelétricos são mais freqüentemente utilizados em aplicações aeroespaciais e automotivas. Os sensores e atuadores piezocerâmicos, são leves e podem ser colados a uma variedade de estruturas. A maioria das pesquisas atuais considera o efeito do acoplamento eletromecânico do PZT com a estrutura base desprezível. No entanto, para técnicas de ajuste de modelos ou aplicações envolvendo localização de falhas em estruturas leves e específicas este efeito deve ser considerado (Lopes Jr *et al.*, 2000).

3 OTIMIZAÇÃO POR NUVEM DE PARTÍCULAS - PSO

A PSO foi desenvolvida inicialmente por Kennedy e Eberhart (1995) baseada nos estudos do sócio-biologista Edward Osborne Wilson (Wilson, 1971; Wilson, 1995). A PSO constitui uma técnica da inteligência coletiva baseada em uma população de soluções e transições aleatórias (Brandstätter e Baumgartner, 2002). A PSO apresenta características similares as técnicas da computação evolutiva, que são baseadas em uma população de soluções. Entretanto, a PSO é motivada pela simulação de comportamento social e cooperação entre agentes em vez da sobrevivência do indivíduo mais apto como nos algoritmos evolutivos. Na PSO, cada solução candidata (denominada de partícula) possui associada uma velocidade. A velocidade é ajustada através de uma equação de atualização que considera a experiência da partícula correspondente e a experiência das outras partículas presentes na população (Shi e Eberhart, 1998, 1999).

O conceito da PSO consiste de, a cada passo iterativo, mudar a velocidade de cada partícula em direção as localizações do *pbest* (melhor posição) e do *gbest* (melhor partícula). A rapidez do procedimento de busca é ponderada através de um termo gerado de forma aleatória, sendo este vinculado de forma separada as localizações do *pbest* e do *gbest*. O procedimento para implementação da PSO é regido pelas seguintes etapas:

- (i) iniciar uma população (matriz) de partículas, com posições e velocidades em um espaço de problema n dimensional, aleatoriamente com distribuição uniforme;
- (ii) para cada partículas, avaliar a função de aptidão (função objetivo);
- (iii) comparar a avaliação da função de aptidão da partícula com o $pbest$ da partícula. Se o valor corrente é melhor que $pbest$, então o valor de $pbest$ passa a ser igual ao valor da função de aptidão da partícula, e a localização do $pbest$ passa a ser igual a localização atual no espaço n dimensional;
- (iv) comparar a avaliação da função de aptidão com o prévio melhor valor de aptidão da população. Se o valor atual é melhor que o $gbest$, atualizar o valor de $gbest$ para o índice e valor da partícula atual;
- (v) modificar a velocidade e a posição da partícula de acordo com as equações (10) e (11), respectivamente:

$$v_i = w \cdot v_i + c_1 \cdot ud \cdot (p_i - x_i) + c_2 \cdot Ud \cdot (p_g - x_i) \quad (10)$$

$$x_i = (x_i + \Delta t \cdot v_i) \quad (11)$$

onde Δt é igual a 1.

- (vi) ir para a etapa (ii) até que um critério de parada seja encontrado, usualmente um valor de erro pré-definido ou um número máximo de iterações (gerações).

As notações usadas são: $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T$ armazena a posição da i -ésima partícula, $v_i = [v_{i1}, v_{i2}, \dots, v_{in}]^T$ armazena a velocidade da i -ésima partícula e $p_i = [p_{i1}, p_{i2}, \dots, p_{in}]^T$ representa a posição do melhor valor de aptidão da i -ésima partícula. O índice g representa o índice da melhor particular entre todas as partículas do grupo. A variável w é a ponderação de inércia, c_1 e c_2 são constantes positivas; ud e Ud são duas funções para geração de números aleatórios com distribuição uniforme no intervalo $[0,1]$, respectivamente. O tamanho da população é selecionado dependendo do problema.

As velocidades das partículas em cada dimensão são limitadas a um valor máximo de velocidade, V_{max} . O V_{max} é importante, pois determina a resolução que a região próxima às soluções atuais são procuradas. Se V_{max} é alto, a PSO facilita a busca global, enquanto um valor V_{max} pequeno enfatiza as buscas locais. A primeira parte na equação (10) é um termo de momento da partícula. A ponderação de inércia w representa o grau de momento da partícula. A segunda

parte consiste da parte “cognitiva”, que representa o “conhecimento” independente da partícula. A terceira parte é a “social”, que representa a colaboração entre as partículas.

As constantes c_1 e c_2 representam a ponderação das partes de “cognição” e “social” que influenciam cada partícula em direção a $pbest$ e a $gbest$. Estes parâmetros são usualmente ajustados por heurísticas de tentativa e erro. Neste contexto, a literatura que aborda o ajuste das constantes c_1 e c_2 é extensa (Kennedy *et al.*, 2001; Carlisle e Doizier, 2001; Eberhart e Shi, 2001; Hu e Eberhart, 2001; Clerc e Kennedy, 2002; Robinson e Samii, 2004; Ratnaweera *et al.*, 2004; Van den Bergh e Engelbrecht, 2006).

Segundo Ratnaweera *et al.* (2004), a redução da componente cognitiva e aumento da componente social durante o início da otimização pelo PSO pode ser uma alternativa viável, pois um valor maior de componente cognitiva c_1 e pequeno valor da componente social c_2 no início da otimização incentivam as partículas a moverem-se pelo espaço de busca em vez de moverem-se em direção a melhor partícula da população. Em contra partida, um pequeno c_1 e um grande valor de c_2 ao final da otimização permite as partículas convergirem para um ótimo local no final da otimização.

No entanto, apesar de diversas heurísticas terem sido desenvolvidas, nos últimos anos, para melhorar o desempenho e escolha adequada de parâmetros para o algoritmo PSO (Shi e Eberhart, 1998; Shi e Eberhart, 1999; Kennedy *et al.*, 2001; Clerc e Kennedy, 2002; Pan *et al.*, 2006) ainda não foi apresentada uma proposta que seja comprovadamente superior as outras apresentadas na literatura. Neste contexto, deve-se mencionar que várias abordagens da literatura estão objetivando a prova de convergência do PSO sob determinadas condições de projeto de w , c_1 e c_2 , a citar os trabalhos de Clerc e Kennedy (2002), Trelea (2003), Emara e Fattah (2004), Van den Bergh e Engelbrecht (2006) e Kadirkamanathan *et al.* (2006).

3.1 Abordagens de PSO usando distribuição Gaussiana e de Cauchy

A utilização de uma distribuição de probabilidade uniforme para gerar números aleatórios para atualizar a velocidade é uma abordagem clássica em PSO. Entretanto, a utilização de outras distribuições de probabilidade em pode melhorar a habilidade de ajuste fino na busca pelo PSO ou mesmo para escapar de ótimos locais.

Na literatura tem sido proposta a utilização de distribuições de probabilidade Gaussiana e Cauchy para geração de números aleatórios para atualização da equação da velocidade do PSO, estas inspiradas nos estudos de operadores de mutação em algoritmos de programação evolutiva rápida (*fast*

evolutionary programming) (Yao e Liu, 1996; Chellapilla, 1998). Neste contexto, alguns trabalhos recentes sobre PSO têm abordado este assunto. Por exemplo, os trabalhos de Miranda e Fonseca (2002), Wei *et al.* (2002), Secrest e Lamont (2003), Kennedy (2003), Higashi e Iba (2003), Stacey *et al.* (2003), Esquivel e Coello (2003), Coelho e Krohling (2003) e Krohling (2004).

As abordagens de PSO propostas e avaliadas, neste artigo, são baseadas nos estudos de Coelho e Krohling (2003) e Krohling (2004). Esta abordagem visa modificar a equação (10) do PSO convencional – PSO do tipo 1 – para utilizá-la com diferentes combinações das distribuições uniforme, Gaussiana ou de Cauchy.

A utilização de distribuição de Cauchy em algoritmos evolutivos pode ser útil para evitar mínimos locais quando o espaço de busca é pequeno. Enquanto, a distribuição Gaussiana (normal) pode prover uma convergência mais rápida em buscas locais quando o espaço de busca é grande. As abordagens, para modificação da equação (10) do PSO convencional, propostas e avaliadas são:

Tipo 2: Utilização de uma função com distribuição de Cauchy modificada, cd , para geração de números aleatórios no intervalo $[0,1]$ da parte “cognitiva”:

$$v_i = w \cdot v_i + c_1 \cdot cd \cdot (p_i - x_i) + c_2 \cdot Ud \cdot (p_g - x_i) \quad (12)$$

Tipo 3: Utilização de uma função com distribuição de Cauchy modificada, Cd , para geração de números aleatórios no intervalo $[0,1]$ da parte “social”:

$$v_i = w \cdot v_i + c_1 \cdot ud \cdot (p_i - x_i) + c_2 \cdot Cd \cdot (p_g - x_i) \quad (13)$$

Tipo 4: Utilização de uma função com distribuição de Cauchy modificada, cd e Cd , para geração de números aleatórios no intervalo $[0,1]$, tanto na parte “cognitiva” quanto na “social”:

$$v_i = w \cdot v_i + c_1 \cdot cd \cdot (p_i - x_i) + c_2 \cdot Cd \cdot (p_g - x_i) \quad (14)$$

Tipo 5: Utilização de uma função com distribuição de Gauss (normal), gd , para geração de números aleatórios no intervalo $[0,1]$ na parte “cognitiva”:

$$v_i = w \cdot v_i + c_1 \cdot gd \cdot (p_i - x_i) + c_2 \cdot Ud \cdot (p_g - x_i) \quad (15)$$

Tipo 6: Utilização de uma função com distribuição de Gauss (normal), Gd , para geração de números aleatórios no intervalo $[0,1]$ na parte “social”:

$$v_i = w \cdot v_i + c_1 \cdot ud \cdot (p_i - x_i) + c_2 \cdot Gd \cdot (p_g - x_i) \quad (16)$$

Tipo 7: Utilização de uma função com distribuição de Gauss (normal), gd e Gd , para geração de números aleatórios no intervalo $[0,1]$, tanto na parte “cognitiva” quanto na parte “social”:

$$v_i = w \cdot v_i + c_1 \cdot gd \cdot (p_i - x_i) + c_2 \cdot Gd \cdot (p_g - x_i) \quad (17)$$

Tipo 8: Utilização de uma função com gd na parte “cognitiva” e Cd na parte “social”:

$$v_i = w \cdot v_i + c_1 \cdot gd \cdot (p_i - x_i) + c_2 \cdot Cd \cdot (p_g - x_i) \quad (18)$$

Tipo 9: Utilização de uma função com Gd na parte “social” e cd na parte “cognitiva”:

$$v_i = w \cdot v_i + c_1 \cdot cd \cdot (p_i - x_i) + c_2 \cdot Gd \cdot (p_g - x_i) \quad (19)$$

4 METODOLOGIA DE ANÁLISE

A proposta deste trabalho é a identificação de danos em duas fases distintas. Na primeira etapa se determina a localização da falha através do método de impedância elétrica. Este método é baseado em altas faixas de frequência e modos locais e, portanto, a área de influência de cada atuador é pequena e define com boa exatidão a região da localização da falha. É importante notar que este método não é capaz de fornecer a severidade da falha. A segunda parte desta metodologia fornece informações quantitativas da falha, através de um método de otimização.

O problema direto, que consiste na determinação da variação das propriedades modais em função das variações físicas da estrutura, tem solução única. No entanto, a caracterização de falhas, que é um problema inverso, não apresenta solução única. Qualquer método de otimização que pretenda ajustar o modelo terá grande chance de fracassar para sistemas com nível médio de complexidade ou maior. Existem vários métodos de redução dos modelos ou de escolha das variáveis que serão utilizadas no ajuste. Entre os mais utilizados, pode-se citar o método de sensibilidade; no entanto, a falha pode ocorrer em posições onde a variação daqueles parâmetros apresenta baixa sensibilidade.

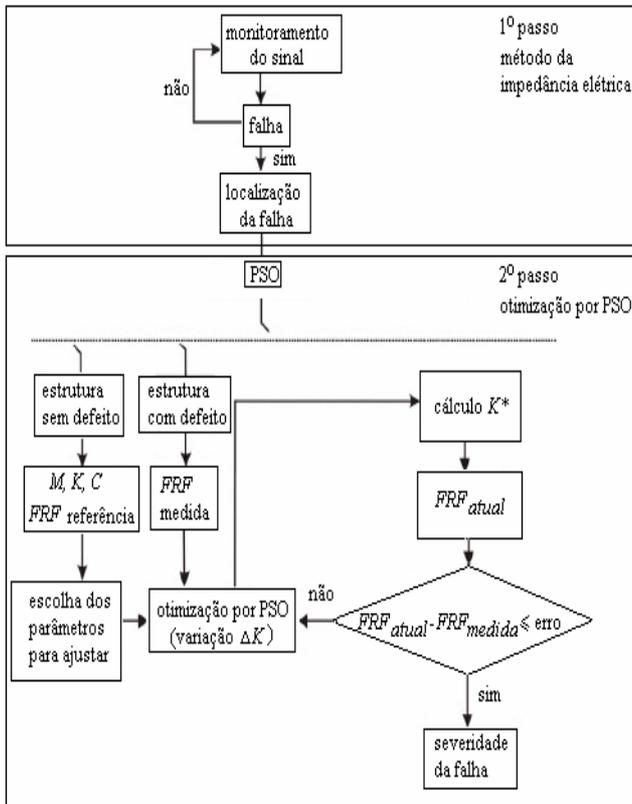


Figura 3: Fluxograma esquemático da metodologia proposta.

A principal vantagem da proposta híbrida apresentada neste trabalho é que o método de impedância elétrica define com exatidão a localização da falha e com isto é possível reduzir o número de variáveis que serão utilizadas no processo de otimização. O método de otimização empregado é baseado em modelo matemático, portanto, é necessário que o modelo inicial da estrutura seja confiável. A figura 3 mostra um fluxograma da metodologia proposta, onde M representa a matriz de massa, K a matriz de rigidez e C a matriz de amortecimento.

A escolha dos parâmetros, que serão utilizados para quantificar a falha, é realizada após a localização da região da falha. Após a definição destes parâmetros, estima-se a variação ocorrida na estrutura em função da falha, obtendo novos valores para M^* , K^* e C^* . A FRF_{atual} , obtida com estes novos valores, é, então, ajustada a FRF_{medida} (situação com defeito) através da técnica de otimização utilizando PSO. Quando a diferença entre estas curvas é menor que um valor especificado o processo termina e a diferença entre as matrizes do sistema sem falha, M , K e C , e das matrizes M^* , K^* e C^* fornece a severidade do defeito.

A otimização foi realizada utilizando a PSO descrita na seção 3. No exemplo mostrado a seguir as matrizes de massa,

M , e de rigidez, K , foram determinadas através do método de Elementos Finitos. A matriz de amortecimento, C , é considerada proporcional a massa e a rigidez. Para a estrutura com defeito foi considerada apenas variação na rigidez K^* .

A falha métrica foi usada neste trabalho como um índice para monitorar a ocorrência de falhas e, é definida como a soma das diferenças quadráticas das mudanças de impedância para cada frequência. Este índice simplifica a interpretação das variações de impedância mecânica da estrutura (Lopes Jr *et al.*, 2000). O monitoramento de cada PZT é feito separadamente, isto é, cada PZT é continuamente monitorado na faixa de frequência especificada. Para cada PZT, deve-se definir um valor mínimo, acima do qual é uma indicação de falha naquela região. As condições de operação e variações de temperatura podem mudar as características dinâmicas da estrutura. O valor mínimo é definido por tentativa e erro, ou conhecimento da dinâmica estrutural do sistema. A falha métrica, M , é dada por:

$$M = \sum_{i=1}^n [Z_{i,1} - Z_{i,2}]^2 \quad (20)$$

em que $Z_{i,1}$ é a impedância medida na estrutura intacta; $Z_{i,2}$ é a impedância medida na estrutura em condições normais de operação e i é o número de pontos utilizados na aquisição do sinal.

5 RESULTADOS OBTIDOS

As medidas experimentais de impedância elétrica foram realizadas com o analisador de impedância HP 4192A. As curvas de impedância foram avaliadas através do valor da falha métrica. Uma das vantagens em se usar a técnica de impedância elétrica é a possibilidade de identificação de falhas simultâneas, em diferentes estágios de evolução.

Para comprovar a capacidade do PSO foram realizados testes para quantificar as falhas estruturais. Nos testes realizados foram analisadas duas situações de falhas, que consistem em cortes transversais a viga, com largura b e profundidade a . As figuras 4 e 5 mostram a estrutura analisada na condição livre-livre e medidas de impedância elétrica para diferentes profundidades de falhas na posição 2, medidas com o PZT número 2, respectivamente.

O método de quantificação de falhas consiste em minimizar uma função de custo (função objetivo), que possa representar diferenças, em alguma norma, entre as respostas medida e numérica. A função adotada neste trabalho para caracterizar a falha pode ser matematicamente expressa como:

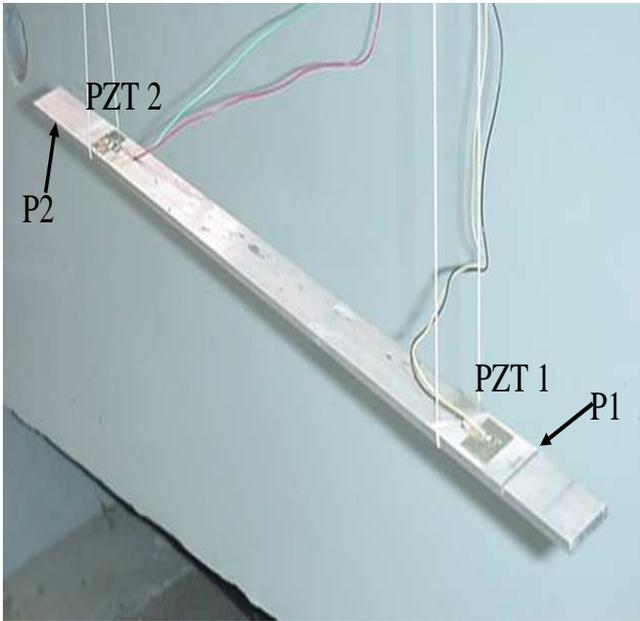


Figura 4: Estrutura utilizada, mostrando a situação de falhas nas posições P1 e P2.

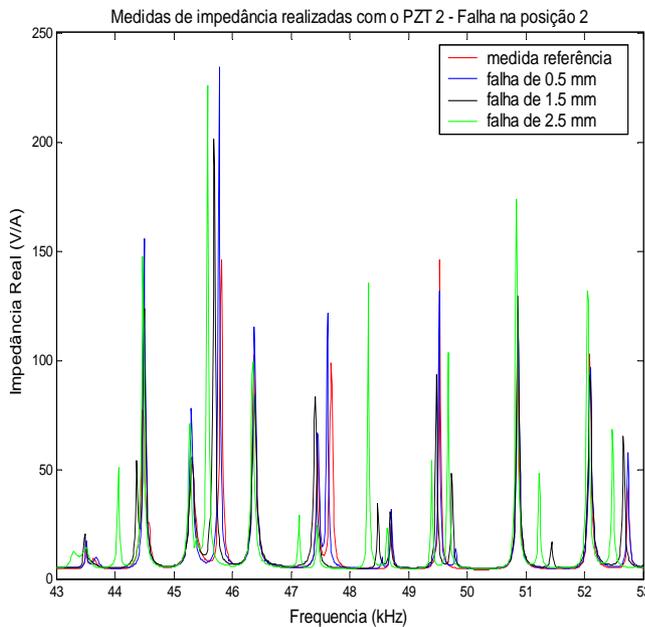


Figura 5: Medidas de impedância elétrica realizadas com o PZT 2.

$$f_m = f_{medida}(1 : 7) \quad (21)$$

$$f_{aj} = f_{atual}(1 : 7) \quad (22)$$

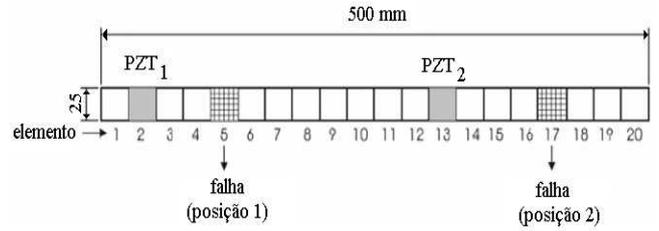


Figura 6: Posição das falhas e dos PZTs na estrutura analisada.

$$Fxe = \sum_{i=1}^7 |f_m - f_{aj}| \quad (23)$$

onde f_{medida} e f_{atual} são os valores das sete primeiras freqüências naturais, obtidas segundo a metodologia apresentada na figura 3. O valor Fxe considera a somatória dos erros das sete primeiras freqüências naturais. A função de aptidão (*fitness function*) usada na PSO visa a maximização do valor, portanto, se utiliza o inverso da equação (23).

A figura 6 mostra um desenho esquemático da estrutura analisada. A viga é feita de alumínio com dimensões 500, 25 e 5 mm de comprimento, largura e espessura, respectivamente. A viga é engastada em uma extremidade e livre na outra. Para a modelagem em elementos finitos se considerou o elemento do tipo *Beam* e o programa foi implementado no *software* Matlab, da empresa MathWorks. A estrutura foi modelada com 21 nós e foram considerados 2 graus de liberdade por nó (translação em y e rotação em z). Na primeira situação de dano é considerada uma falha na região do PZT 1 (ou seja, falha no elemento 5 da estrutura). Na segunda situação de dano é considerada uma outra falha na estrutura no elemento 17 (região do PZT 2), caracterizando, portanto, uma situação de falhas simultâneas.

As propriedades do material piezelétrico são baseadas no material designado por PSI-5A-S4 (Piezo Systems, Inc.) e são dadas na tabela 1.

Tabela 1: Propriedades do material PZT.

$E_P = 63 \text{ GPa}$	$\rho_P = 7650 \text{ kg/m}^3$
$d_{31} = -190 \times 10^{-12} \text{ m/V}$	$d_{33} = -190 \times 10^{-12} \text{ m/V}$
$c_{11} = 1,07 \times 10^{11} \text{ N/m}^2$	$K^T = 1800$
$E_P = 30,705 \text{ N.m/V.m}^2$	$\varepsilon_{33}^S = 7,33 \times 10^{-9} \text{ F/m}$

Na estrutura especificada acima, foram realizados diferentes testes. As falhas foram implementadas através de sucessivos acréscimos na profundidade do corte. Os resultados podem ser avaliados através de dois estudos de caso (observando-

se a configuração apresentada na figura 5). No primeiro se considerou uma redução de 20% no momento de inércia do elemento 5. No segundo caso se considerou uma redução no momento de inércia de 20% no elemento 5 e de 15% no elemento 17, ou seja, a ocorrência de falhas simultâneas. Esta situação corresponde ao maior dano que foi introduzido na estrutura. No entanto, destaca-se que através do primeiro passo da metodologia foi possível detectar a falha desde seu estagio inicial.

5.1 Estudo de caso 1: Dano no elemento 5

Caso 1(a): Otimização do elemento 5

Neste caso se considera que a primeira etapa da metodologia fornece a posição exata da falha. Portanto, o programa ajusta apenas a rigidez do elemento 5. A figura 7 mostra as curvas das *FRFs* para as situações sem falha e com falha. Nesta figura, o *zoom* na região entre 400 e 1100 Hz mostra a pequena variação das curvas. O objetivo da PSO é a partir da curva sem falha (em azul) ajustar à curva com falha (em vermelho) e assim, através das diferenças entre matrizes, quantificar a falha presente na estrutura.

O caso 1(a) é uma situação ideal e de complexidade relativamente simples, pois para a implementação na PSO a quantificação da falha pode ser comparada com um problema de otimização com apenas uma variável. Para clareza do texto, os resultados deste caso não serão apresentados.

Caso 1(b): Otimização das regiões 4, 5 e 6

Neste exemplo se verifica a capacidade da PSO quantificar a falha quando a técnica da impedância elétrica localiza uma região de falha, ou seja, a técnica informa que a falha está presente e localizada numa região envolvendo os elementos 4, 5 e 6. Neste caso, os valores ideais a serem alcançados pela PSO são:

- I^4 : momento de inércia do elemento 4 (valor ideal 1,000);
- I^5 : momento de inércia do elemento 5 (valor ideal 0,800);
- I^6 : momento de inércia do elemento 6 (valor ideal 1,000).

Nas tabelas 2 a 5 é apresentada uma análise estatística do desempenho das abordagens de PSO para 30 experimentos. As tabelas 2 a 5 apresentam, também, o valor médio, o valor mínimo, o valor máximo e desvio padrão destes resultados. Os parâmetros da PSO utilizados para obtenção destes resultados foram:

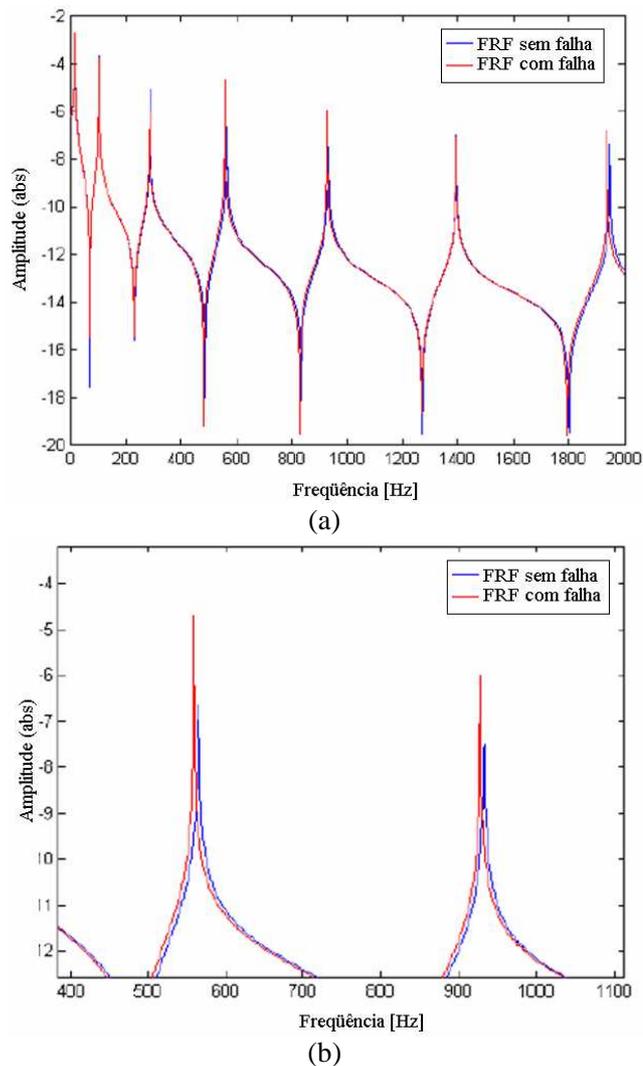


Figura 7: (a) *FRFs* da estrutura na situação sem falha e com falha; (b) *zoom* na faixa de frequências de 400 a 1100 Hz.

- tamanho da população: 30 partículas;
- espaço de busca das variáveis de momento de inércia I^4, I^5, I^6 (m^4): $0 < I^4 \leq 2, 0 < I^5 \leq 2$ e $0 < I^6 \leq 2$;
- V_{max} : 20% do espaço de busca de cada variável;
- número máximo de gerações (critério de parada): 100 gerações.

Foram realizados testes com as seguintes configurações de PSO:

- $c_1 = c_2 = 2,0$ (valor constante);
- c_1 e c_2 variantes no tempo com valores regidos pelas seguintes equações (Ratnaweera *et al.*, 2004):

$$c_1 = (c_{1f} - c_{1i}) \frac{g}{G} + c_{1i} \quad (24)$$

$$c_2 = (c_{2f} - c_{2i}) \frac{g}{G} + c_{2i} \quad (25)$$

onde g é geração (iteração) atual, G é o número máximo de gerações (critério de parada); adotou-se a configuração proposta por Ratnaweera *et al.* (2004) com $c_{1i} = 2,5$, $c_{1f} = 0,5$, $c_{2i} = 0,5$ e $c_{2f} = 2,5$.

(iii) fator de inércia com decréscimo linear,

$$w = \frac{G - g}{G} (w_i - w_f) + w_f \quad (26)$$

onde o valor inicial de w é $w_i=0,9$ e valor final de w é $w_f=0,5$ (Kennedy *et al.*, 2001).

(iv) nova proposta de fator de inércia com decréscimo regido pela parte real de um sinal exponencial complexo,

$$w = Re [\exp(-0,5g/G) + \cos(20g)] \quad (27)$$

onde o valor do co-seno é dado em radianos. Neste caso, o objetivo é enfatizar buscas globais pela PSO.

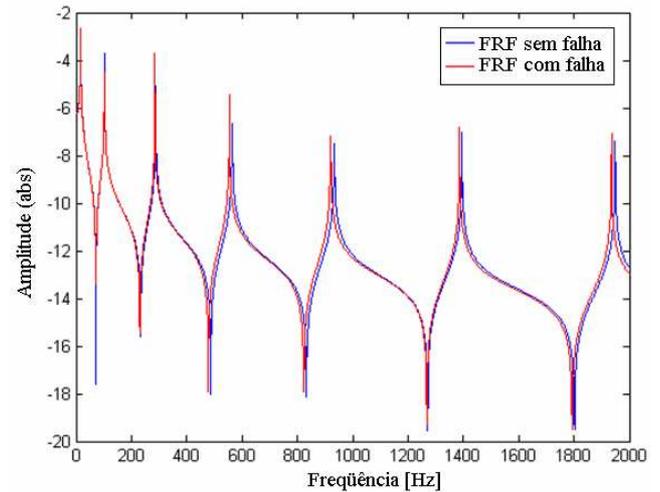
Nota-se que o PSO(8) apresentou melhor convergência dos resultados (média da função objetivo) nas tabelas 3 e 5. Contudo, o PSO(2), PSO(8), PSO(6) e PSO (2) obtiveram o melhor resultado (mínimo da função objetivo) para as abordagens das tabelas 2, 3, 4 e 5, respectivamente. Neste caso, os resultados de I^4 , I^5 e I^6 foram muito próximos dos valores ideais, pois $I^4 = 0,9998$, $I^5 = 0,8000$ e $I^6 = 0,9999$.

Os algoritmos de PSO foram testados usando Matlab 5.2 em um computador com processador AMD Athon 1,10 GHz e memória RAM de 112 MB. O tempo médio, para a realização de 30 experimentos, foi de aproximadamente 56 segundos e 15 minutos para os caso 1(b).

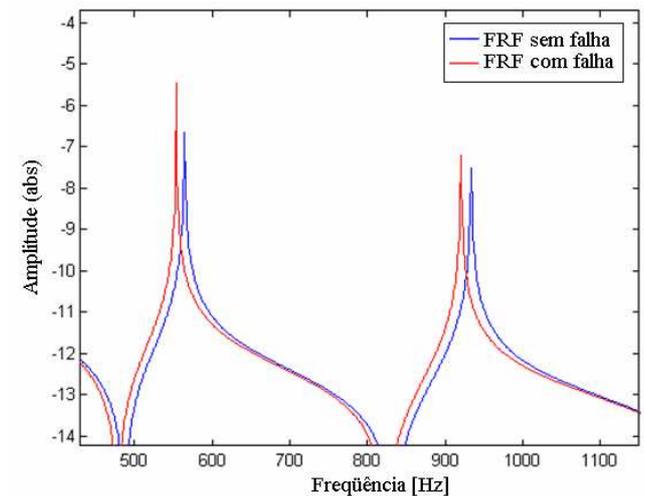
5.2 Estudo de caso 2: Falhas simultâneas nos elementos 5 e 17

Neste estudo de caso são testadas as falhas simultâneas nos elementos 5 e 17. As situações de falha simultânea na estrutura foram: alteração de 20% no momento de inércia do elemento 5 e 15% de alteração no momento de inércia do elemento 17. A figura 8 mostra as *FRFs* para os casos sem falha (curva em azul) e com falhas simultâneas (curva em vermelho).

Neste caso, os valores ideais a serem alcançados pela PSO são:



(a)



(b)

Figura 8: (a) *FRFs* da estrutura na situação sem falha e com falha; (b) *zoom* na faixa de frequências de 400 a 1100 Hz.

- I^4 : momento de inércia do elemento 4 (valor ideal 1,000);
- I^5 : momento de inércia do elemento 5 (valor ideal 0,800);
- I^{16} : momento de inércia do elemento 16 (valor ideal 1,000);
- I^{17} : momento de inércia do elemento 17 (valor ideal 0,850).

Nas tabelas 6 a 9 é apresentada uma análise estatística (valor médio, valor mínimo, valor máximo e desvio padrão) do desempenho das abordagens de PSO para 30 experimentos. Os parâmetros da PSO utilizados para obtenção destes resultados foram:

- tamanho da população: 30 partículas;
- espaço de busca das variáveis de momento de inércia I^4, I^5, I^{16}, I^{17} (m^4): $0 < I^4 \leq 2, 0 < I^5 \leq 2, 0 < I^{16} \leq 2$ e $0 < I^{17} \leq 2$;
- V_{max} : 20% do espaço de busca de cada variável;
- número máximo de gerações (critério de parada): 100 gerações.

No caso 2 foram utilizadas as mesmas configurações de c_1, c_2 e w do caso 1(b). Nota-se pelos resultados das tabelas 6 a 9, que o menor valor de função objetivo foi obtida com o PSO(5) com 15,6220 e valores de $I^4=1,0000, I^5=0,7994, I^{16}=1,0013$ e $I^{17}=0,8491$. Estes valores estão próximos os valores ideais mencionados.

Os algoritmos de PSO foram testados no mesmo computador do caso 1(b). Neste caso 2, o tempo médio, para a realização de 30 experimentos, foi de aproximadamente 104 segundos.

Nota-se pelas tabelas 6 a 9 que os resultados obtidos com as abordagens de PSO apresentados nas tabelas 8 e 9 foram superiores em termos de valores médios de função objetivo com relação aos resultados apresentados nas tabelas 6 e 7.

5.3 Estudo comparativo do PSO com outras estratégias de otimização

Na tabela 10 é apresentado um estudo comparativo de melhor geração de solução para os casos 1 e 2. Neste contexto, foram comparados para mesmo tamanho de população e critério de parada, os melhores resultados obtidos com o PSO deste trabalho e as abordagens clássicas de: (i) algoritmos genéticos (Tebaldi, 2004); (ii) programação evolutiva (Tebaldi *et al.*, 2003) e (iii) estratégia evolutiva com mecanismos de auto-adaptação (Tebaldi *et al.*, 2005).

Nota-se pela tabela 10, que o PSO apresentou melhores resultados em relação aos obtidos pelas outras estratégias de otimização, com destaque para o caso de falha simultânea. Baseado nestes resultados, os autores acreditam que quanto maior o número de variáveis envolvidas no processo, mais vantajosa se torna a aplicação da técnica PSO. Os melhores resultados foram obtidos com a PSO seguidos dos resultados obtidos com a estratégia evolutiva.

6 DISCUSSÃO E CONCLUSÃO

A tecnologia de materiais inteligentes se tornou uma área de crescente interesse para o desenvolvimento de estruturas que podem incorporar atuadores e sensores capazes de detectar as falhas. Extensivas investigações têm sido focadas na tecnologia que integra materiais inteligentes no monitoramento

das condições de sistemas. Vários estudos têm sido realizados na área de identificação de sistemas mecânicos e há uma tendência de introduzir otimização em sistemas de monitoramento da condição da máquina. Este procedimento permite a automatização do processo e a caracterização on-line de falhas estruturais. O problema de identificação de variáveis ou detecção de falhas em sistemas mecânicos é uma classe de problema inverso e, portanto, não apresenta uma solução única. O problema inverso consiste em determinar as causas baseando-se na observação dos efeitos. Nos problemas inversos os parâmetros de falha (comprimento de trinca e/ou localização) podem ser calculados no domínio da frequência ou do tempo.

A primeira etapa desta metodologia utiliza o método da impedância elétrica para determinar a localização das falhas. Esta técnica é baseada na aplicação de forças de excitação de pequena amplitude e altas faixas de frequências. Geralmente, utiliza-se tensão elétrica de 1 Volt no PZT e frequências maiores que 20 kHz. Isto faz com que apenas os modos locais de vibração sejam excitados, definindo uma área de influência para cada PZT. Esta característica torna possível a identificação de falhas incipientes nestas áreas de influência de cada sensor/atuador PZT. Na segunda etapa é realizada a quantificação da severidade das falhas usando PSO. A PSO é baseada em uma população de indivíduos (possíveis soluções do problema) e é motivada pela simulação de comportamento social em vez da sobrevivência do indivíduo mais apto.

Neste artigo a caracterização das falhas foi avaliada em uma estrutura com materiais piezelétricos incorporados. As abordagens de PSO implementadas apresentaram resultados precisos e promissores para os casos estudados neste artigo.

A proposta de aplicação conjunta das técnicas de impedância elétrica e da PSO pode oferecer um critério robusto e eficiente para identificação de danos estruturais. Pois, na primeira etapa desta metodologia, a localização da falha pode ser determinada com exatidão e assim os parâmetros de ajuste são reduzidos drasticamente. As vantagens da PSO aliadas ao pequeno número de variáveis a ajustar nos fazem acreditar na potencialidade do método.

Em trabalhos futuros, deseja-se aplicar outras técnicas de otimização da computação evolutiva e inteligência coletiva, para comparação com a das abordagens de PSO para detecção de falhas em estruturas de maior complexidade.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPESP, Fundação de Apoio a Pesquisa do Estado de São Paulo, o editor associado e aos revisores deste trabalho, que contribuíram significativamente através de suas sugestões.

REFERÊNCIAS

- Ayres, J. W. (1996). Qualitative health monitoring and incipient damage inspection/ evaluation, *Master thesis*, Virginia Polytechnic Institute and State University – CIMSS, USA.
- Banks, H. T.; Inman, D. J.; Leo, D. J.; Wang, Y. (1996). An experimentally validated damage detection theory in smart structures, *Journal of Sound and Vibrations*, vol. 191, no. 5, pp. 859-880.
- Baras, J. S.; Tan, X.; Hovareshti, P; (2003). Decentralized control of autonomous vehicles, *Proceedings of the 42nd IEEE Conference on Decision and Control*, Maui, HI, USA, pp. 1532-1537.
- Brandstätter, B.; Baumgartner, U. (2002). Particle swarm optimization – mass-spring systems analogon, *IEEE Transactions on Magnetics*, vol. 38, no. 2, pp. 997-1000.
- Carlisle, A.; Dozier, G. (2001). An off-the-shelf PSO, *Proceedings of the Workshop on Particle Swarm Optimization*, Indianapolis, IN, USA.
- Chellapilla, K. (1998). Combining mutation operators in evolutionary programming, *IEEE Transactions on Evolutionary Computation*, vol. 2, no. 3, pp. pp. 91-96.
- Chen, J.; Patton, R. J. (1993). Robust model-based fault diagnosis for dynamic systems, Kluwer Academic Publishers, Boston, MA, USA.
- Clark, R. L.; Saunders, W. R.; Gibbs, G. P. (1998). Adaptive structures: dynamics and control, John Wiley and Sons, Inc.
- Clerc, M.; Kennedy, J. (2002). The particle swarm: explosion, stability, and convergence in a multi-dimensional complex space, *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 1, pp. 58-73.
- Coelho, L. S.; R. A. Krohling (2003). Predictive controller tuning using modified particle swarm optimisation based on Cauchy and Gaussian distributions, *Proceedings of the 8th Online World Conference on Soft Computing in Industrial Applications*, WSC8, Dortmund, Germany.
- de Castro, L. N. (2001). *Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais*, Tese de doutorado, DCA/UNICAMP, Campinas, SP.
- Doebbling, S. W.; Farrar, C. R.; Prime, M. B. (1998). A summary review of vibration based damage identification methods, *The Shock and Vibration Digest*, Thousand Oaks, vol. 30, no. 2, pp. 91-105.
- Dorigo, M.; Di Caro, G. (1999). The ant colony optimization meta-heuristic, in D. Corne, M. Dorigo, F. Glover (editors), *New ideas in optimization*, McGraw-Hill, pp. 11-32.
- Dosch, J. J.; Inman, D. J.; Garcia, E. (1992). Self-sensing piezoelectric actuator for collocated control, *Journal of Intelligent Material Systems and Structures*, vol. 3, no. 1, pp. 166-185.
- Eberhart, R. C.; Shi, Y. (2001). Tracking and optimizing dynamic systems with particle swarms, *Proceedings of Congress on Evolutionary Computation*, Seoul, Korea, pp. 94-97.
- Emara, H. M.; Fattah, H. A. A. (2004). Continuous swarm optimization technique with stability analysis, *Proceedings of American Control Conference*, Boston, MA, USA, pp. 2811-2817.
- Esquivel, S. C.; Coello, C. A. C. (2003). On the use of particle swarm optimization with multimodal functions, *Proceedings of the IEEE Congress on Evolutionary Computation*, Canberra, Australia, pp. 1130-1136.
- Fourie, P. C.; Groenwold, A. A. (2002). The particle swarm optimization algorithm in size and shape optimization, *Structural and Multidisciplinary Optimization*, vol. 23, no. 4, pp. 259-267.
- Friswell, M. I.; Penny, J. E. (1997). The practical limits of damage detection and location using vibration data, *Proceedings of 11th VPI and SU Symposium on Structural Dynamics and Control*, Blacksburg, VA, USA, 1-10.
- Friswell, M. I.; Penny, J. E. T.; Garvey, S. D. (1998). A Combined genetic and eigensensitivity algorithm for the location of damage in structures, *Computers and Structures*, vol. 69, no. 5, pp. 547-556.
- Gabbert, U.; Berger, H.; Koppe, H.; Cao, X. (1998). On modelling and analysis of piezoelectric adaptive structures by the finite element method, *Proceedings of 4th European Conference on Smart Structures*, Harrogate, UK, pp. 621-628
- He, Y.; Guo, D.; Chu, F. (2001). Using genetic algorithms to detect and configure shaft crack for rotor-bearing system, *Computer Methods in Applied Mechanics and Engineering*, vol. 190, no. 45, pp. 5895-5906.
- Higashi, N.; Iba, H. (2003). Particle swarm optimization with Gaussian mutation, *Proceedings of the IEEE Swarm Intelligence Symposium*, Indianapolis, IN, USA, pp. 72-79.

- Hu, X.; Eberhart, R. C. (2001). Tracking dynamic systems with PSO: where's the cheese?, *Proceedings of the Workshop on Particle Swarm Optimization*, Indianapolis, IN, USA.
- Inman, D. J. (1990). Control/structure interaction: effects of actuator dynamics, *AIAA Dynamics Specialist Conference*, Washington, DC, USA, pp. 311-321.
- Inman, D. J. (1996). *Engineering vibration*, Prentice Hall, NJ, USA.
- Inman, D.J., Farrar, C.R., Lopes Jr., V. and Steffen Jr. V. (2005). Damage prognosis for Aerospace, Civil and Mechanical Systems, John Wiley and Sons.
- Kabeya, K. (1998). Structural health monitoring using multiple piezoelectric sensors and actuators, *Master thesis*, Virginia Polytechnic Institute and State University – CIMSS, USA.
- Kadirkamanathan, V.; Selvarajah, K.; Fleming, P. J. (2006). Stability analysis of the particle dynamics in particle swarm optimizer, *IEEE Transactions on Evolutionary Computation*, vol. 10, no. 3, pp. 245-255.
- Kaminski, P. C. (1997). *Um sistema de diagnóstico de falhas estruturais baseado em redes neurais artificiais e frequências naturais*, Tese de livre docência, Escola Politécnica da Universidade de São Paulo, São Paulo, SP.
- Kannan, S.; Slochanal, S. M. R.; Subbaraj, P.; Padhy, N. P. (2004). Application of particle swarm optimization technique and its variant to generation expansion planning problem, *Electric Power Systems Research*, vol. 70, no. 3, pp. 203-210.
- Kennedy, J. (2003). Bare bones particle swarms, *Proceedings of the IEEE Swarm Intelligence Symposium*, Indianapolis, IN, USA, pp. 80-87.
- Kennedy, J. F.; Eberhart, R.C.; Shi, Y. (2001). *Swarm intelligence*. San Francisco, CA, USA: Morgan Kaufmann.
- Kennedy, J.; Eberhart, R. C. (1995). Particle swarm optimization, *IEEE International Conference on Neural Networks*, Perth, Australia, vol. 4, pp. 1942-1948.
- Kessler, S. S.; Spearing, S. M.; Atalla, M. J. (2002). In-situ damage detection of composites structures using lamb wave methods. *Technical Report EWSHM-2002*, Technology Laboratory for Advanced Composites, Department of Aeronautics and Astronautics Massachusetts Institute of Technology.
- Krohling, R. A. (2004). Gaussian swarm: a novel particle swarm optimization algorithm, *Proceedings of the IEEE Conference on Cybernetics and Intelligent Systems*, Singapore, pp. 372-376.
- Liu, Y.; Passino, K. M. (2004). Stable social foraging swarms in a noisy environment, *IEEE Transactions on Automatic Control*, vol. 49, no. 1, pp. 30-44.
- Lopes Jr., V.; Park, G.; Cudney, H. H.; Inman, D. J. (2000). Impedance-based structural health monitoring with artificial neural network, *Journal of Intelligent Material Systems and Structures*, vol. 11, no. 13, pp. 206-214.
- Marwala, T.; Chakraverty, S. (2006). Fault classification in structures with incomplete measured data using autoassociative neural networks and genetic algorithm, *Current Science*, vol. 90, no. 4, pp. 542-548.
- Miranda, V.; Fonseca, N. (2002). EPSO – Best of two worlds meta-heuristic applied to power system problems, *Proceedings of the IEEE Congress on Evolutionary Computation*, Honolulu, HI, USA, pp. 1080-1085.
- Müller, S. D.; Marchetto, J.; Airaghi, S.; Koumoutsakos, P. (2002). Optimization based on bacterial chemotaxis, *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 1, pp. 16-29.
- Pan, H.; Wang, L.; Liu, B. (2006). Particle swarm optimization for function optimization in noisy environment, *Applied Mathematics and Computation*, Elsevier (aceito para publicação).
- Patton, R. J.; Uppal, F. J.; Lopez-Toribio, C. J. (2000). Soft computing approaches to fault diagnosis for dynamic systems: a survey, *IFAC Symposium SAFEPROCESS 2000*, Budapest, Hungary, pp. 298-311.
- Ratnaweera, A.; Halgamuge, S.; Watson, H. (2004). Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients, *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 3, pp. 240-255.
- Robinson, J.; Samii, Y. R-. (2004). Particle swarm optimization in electromagnetics, *IEEE Transactions on Antennas and Propagation*, vol. 52, no. 2, pp. 397-407.
- Secret, B. R.; Lamont, G. B. (2003). Visualizing particle swarm optimization - Gaussian particle swarm optimization, *Proceedings of the IEEE Swarm Intelligence Symposium*, Indianapolis, IN, USA, pp. 198-204.
- Shi, Y.; Eberhart, R. C. (1998). A modified particle swarm optimizer, *IEEE International Conference on Evolutionary Computation*, Anchorage, AK, USA, pp. 69-73.
- Shi, Y.; Eberhart, R. C. (1999). Empirical study of particle swarm optimization, *IEEE International Conference on Evolutionary Computation*, Washington, DC, USA, pp. 1945-1950.

- Silcox, R. J., Lefebvre, S., Metcalf, V. L., Fuller, C. R. (1992). Evaluation of piezoceramic actuators for control of aircraft interior noise, *Proceeding of 14th Aeroacoustic Conference*, DGLR/AIAA, Aachen, Germany.
- Simões, R. C.; Steffen Jr., V. (2002). Sobre o problema da identificação de falhas em máquinas rotativas, *II Congresso Nacional de Engenharia Mecânica, II CONEM*, João Pessoa, PB (CD-ROM).
- Stacey, A.; Jancic, M.; Grundy, I. (2003). Particle swarm optimization with mutation, *Proceedings of the IEEE Congress on Evolutionary Computation*, Canberra, Australia, pp. 1425-1430.
- Sun, F. (1996). Piezoelectric active sensor and electric impedance approach for structural dynamic measurement, *Master thesis*, Virginia Polytechnic Institute and State University – CIMSS, USA.
- Tebaldi, A. (2004). Detecção de falhas estruturais usando sensores e atuadores piezoelétricos e algoritmos genéticos, *Dissertação de mestrado*, Pós-Graduação em Engenharia Mecânica, Faculdade de Engenharia, Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, SP.
- Tebaldi, A.; Coelho, L. S.; Lopes Jr., V. (2003). Identificação de falhas em estruturas inteligentes baseada em otimização através de programação evolutiva, *XXIV Iberian Latin-American Congress on Computational Methods in Engineering*, XXIV CILAMCE, Ouro Preto, MG.
- Tebaldi, A., Coelho, L. S.; Lopes Jr., V. (2005). Detecção de falhas em estruturas inteligentes usando estratégia evolutiva com mecanismos de auto-adaptação, VII Simpósio Brasileiro de Automação Inteligente, São Luís, MA.
- Trelea, I. C. (2003). The particle swarm optimization algorithm: convergence analysis and parameter selection, *Information Processing Letters*, vol. 85, no. 6, pp. 317-325.
- Tseng, K. K., Wang, L. (2005). Impedance-based method for nondestructive damage identification, *Journal of Engineering Mechanics – ASCE*, vol. 131, no. 1, pp. 58-64.
- Van den Bergh, F.; Engelbrecht, A. P. (2006). A study of particle swarm optimization particle trajectories, *Information Sciences*, vol. 176, pp. 937-971.
- Xu, J.; Yang, Y.; Soh, C. K. (2004). Electromechanical impedance-based structural health monitoring with evolutionary programming, *Journal of Aerospace Engineering*, vol. 17, no. 5, pp. 182-193.
- Yang, Y.; Soh, C. K.; Xu, J. (2005). An integrated evolutionary programming and impedance-based NDE method, *Proceedings of SPIE*, vol. 5647, Smart Structures, Devices, and Systems II, S. F. Al-Sarawi (ed.), pp. 154-161.
- Yao, X.; Liu, Y. (1996). Fast evolutionary programming, *Proceedings of 5th Annual Conference on Evolutionary Programming*, San Diego, CA, USA, pp. 451-460.
- Wei, C.; He, Z.; Zheng, Y.; Pi, W. (2002). Swarm directions embedded in fast evolutionary programming, *Proceedings of the IEEE Congress on Evolutionary Computation*, Honolulu, HI, USA, pp. 1278-1283.
- Wilson, E.O. (1971). *The insect societies*, Belknap Press of Harvard University Press, Cambridge, MA.
- Wilson, E. O. (1995). *Naturalist*, Warner Books, New York, NY, USA.

Tabela 2: Resultados de otimização usando PSO com $c_1 = c_2 = 2$ (constantes) e decréscimo linear do fator de inércia para o caso 1(b) (30 experimentos).

função objetivo						gerações para obter o mínimo da função objetivo				
PSO	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	0,7942	0,1241	0,3709	0,3270	0,1802	98	45	72	72	18
(2)	0,3745	0,0926	0,2533	0,2835	0,1050	98	52	77	78	15
(3)	0,4582	0,1766	0,2867	0,2628	0,0865	97	55	74	71	13
(4)	0,3779	0,1639	0,2485	0,2505	0,0717	97	32	66	67	25
(5)	0,7060	0,1699	0,3101	0,2933	0,1552	100	44	79	83	17
(6)	0,5079	0,1245	0,3275	0,3292	0,1301	100	65	87	92	12
(7)	0,4423	0,1551	0,2751	0,2740	0,0898	94	40	70	75	16
(8)	0,4478	0,1674	0,2872	0,2765	0,0781	98	50	87	90	14
(9)	0,5572	0,1312	0,2615	0,2308	0,1194	94	58	75	71	14
média	0,5184	0,1450	0,2912	0,2808	0,1129	97	49	76	77	16

Tabela 3: Resultados de otimização usando PSO com $c_1 = c_2 = 2$ (constantes) e decréscimo usando função exponencial e co-seno do fator de inércia para o caso 1(b) (30 experimentos).

função objetivo						gerações para obter o mínimo da função objetivo				
PSO	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	0,6265	0,2141	0,3766	0,3657	0,1354	100	50	80	85	20
(2)	0,5241	0,1919	0,3633	0,3470	0,1076	99	27	73	75	21
(3)	0,4928	0,2243	0,3554	0,3443	0,0804	100	30	71	70	25
(4)	0,5931	0,1066	0,3609	0,4076	0,1619	97	49	71	65	17
(5)	0,5033	0,1527	0,3067	0,3168	0,0959	88	51	67	63	14
(6)	0,5871	0,1618	0,3949	0,4202	0,1468	85	35	61	60	18
(7)	0,4381	0,1968	0,3205	0,2952	0,0816	91	29	55	49	21
(8)	0,5435	0,0693	0,2811	0,2879	0,1522	97	46	76	78	16
(9)	0,5739	0,1381	0,3417	0,3197	0,1186	98	33	68	72	21
média	0,5425	0,1617	0,3446	0,3449	0,1200	95	39	69	69	19

Tabela 4: Resultados de otimização usando PSO com c_1 e c_2 variantes e decréscimo linear do fator de inércia para o caso 1(b) (30 experimentos).

função objetivo						gerações para obter o mínimo da função objetivo				
PSO	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	0,2936	0,0666	0,1972	0,2068	0,0827	100	54	74	69	17
(2)	0,4075	0,1602	0,2579	0,2537	0,0797	100	46	78	79	20
(3)	0,3273	0,0593	0,1863	0,1828	0,0809	93	42	77	86	18
(4)	0,2937	0,0615	0,1815	0,1905	0,0829	100	57	82	89	15
(5)	0,4315	0,0536	0,2517	0,2819	0,1146	99	61	84	85	14
(6)	0,2721	0,0493	0,1735	0,1766	0,0620	100	32	79	82	19
(7)	0,3759	0,0587	0,2581	0,2813	0,1028	100	55	77	77	17
(8)	0,3109	0,0820	0,1814	0,1778	0,0637	90	50	72	71	13
(9)	0,2957	0,1391	0,2212	0,2090	0,0518	91	30	60	56	21
média	0,3342	0,0811	0,2120	0,2178	0,0801	97	47	76	77	17

Tabela 5: Resultados de otimização usando PSO com c_1 e c_2 variantes e decréscimo usando função exponencial e co-seno do fator de inércia para o caso 1(b) (30 experimentos).

PSO	função objetivo					gerações para obter o mínimo da função objetivo				
	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	0,3372	0,1135	0,2211	0,2270	0,0657	94	31	65	61	21
(2)	0,3343	0,0414	0,2330	0,2545	0,0885	95	36	61	56	19
(3)	0,2626	0,0481	0,1786	0,1791	0,0638	96	29	64	68	24
(4)	0,3053	0,0381	0,1897	0,1999	0,0763	99	36	73	71	22
(5)	0,4018	0,0688	0,1938	0,1850	0,1078	83	29	56	56	17
(6)	0,2468	0,0976	0,1684	0,1664	0,0460	95	13	61	57	26
(7)	0,3580	0,1021	0,2403	0,2529	0,0881	97	43	70	59	21
(8)	0,2632	0,0573	0,1572	0,1593	0,0710	90	36	65	64	19
(9)	0,2430	0,0850	0,1661	0,1710	0,0520	88	38	63	60	16
média	0,3058	0,0724	0,1942	0,1995	0,0732	93	32	64	61	21

Tabela 6: Resultados de otimização usando PSO com $c_1 = c_2 = 2$ (constantes) e decréscimo linear do fator de inércia para o caso 2 (30 experimentos).

PSO	função objetivo					gerações para obter o mínimo da função objetivo				
	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	193,1899	72,5890	115,6720	112,2666	37,1740	97	67	89	93	10
(2)	131,2629	46,9650	87,1996	87,6621	22,7564	97	57	81	85	12
(3)	130,6144	52,5654	88,6624	89,1310	24,1712	90	62	75	75	10
(4)	102,7698	31,5151	66,3722	54,0174	28,1484	100	57	76	74	14
(5)	196,5371	44,3626	108,8639	100,7812	50,9243	98	76	86	88	8
(6)	183,2158	48,9431	104,0343	112,5530	39,0539	100	86	92	92	4
(7)	189,8996	67,3446	112,3347	109,0274	31,2824	98	56	81	85	14
(8)	137,2103	57,9532	82,6189	73,2948	23,6357	95	49	86	91	15
(9)	124,3716	59,4781	83,8089	78,3118	19,1610	96	63	83	81	11
média	154,3413	53,5240	94,3963	90,7828	30,7008	97	64	83	85	11

Tabela 7: Resultados de otimização usando PSO com $c_1 = c_2 = 2$ (constantes) e decréscimo usando função exponencial e co-seno do fator de inércia para o caso 2 (30 experimentos).

PSO	função objetivo					gerações para obter o mínimo da função objetivo				
	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	179,1551	79,0298	116,8952	109,4406	30,6875	96	55	71	68	13
(2)	156,0991	28,4890	92,0265	89,1844	33,5242	88	40	70	69	16
(3)	149,9794	47,8750	105,5845	106,9327	32,2861	100	46	80	89	21
(4)	134,3865	44,1244	86,8527	80,0509	35,0962	94	44	74	80	16
(5)	164,9183	68,5024	122,1791	116,7635	34,0924	100	52	86	94	16
(6)	122,0664	63,2159	91,8170	93,3065	20,1234	97	46	77	80	18
(7)	174,7487	59,5124	124,5881	137,1295	37,0516	97	41	73	75	17
(8)	121,1739	52,6435	98,6597	107,7126	21,9564	100	39	78	83	19
(9)	160,7948	52,2079	93,9090	94,7725	34,5735	100	52	76	78	15
média	151,4802	55,0667	103,6124	103,9215	31,0435	97	46	76	80	17

Tabela 8: Resultados de otimização usando PSO com c_1 e c_2 variantes e decréscimo linear do fator de inércia para o caso 2 (30 experimentos).

PSO	função objetivo					gerações para obter o mínimo da função objetivo				
	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	96,3871	35,5070	58,8738	54,7828	19,3078	100	72	86	88	10
(2)	90,3414	34,9947	63,8929	67,1440	15,7829	95	41	72	74	18
(3)	95,4500	34,1545	58,7978	54,7508	18,9803	96	57	79	80	12
(4)	81,3561	18,2333	54,6811	50,2061	19,1993	94	57	78	80	14
(5)	119,2573	15,6220	75,4762	77,2767	27,5274	95	63	82	84	10
(6)	89,1132	46,3641	70,6868	69,6558	12,5333	97	30	77	83	21
(7)	115,0005	27,8445	63,2435	60,6496	22,2095	93	64	80	84	9
(8)	99,5002	36,3270	63,7008	61,5898	22,0445	100	64	85	88	12
(9)	94,0783	17,4954	60,6389	63,5748	23,5271	81	43	67	71	14
média	97,8316	29,6158	63,3324	62,1812	20,1236	95	55	78	81	13

Tabela 9: Resultados de otimização usando PSO com c_1 e c_2 variantes e decréscimo usando função exponencial e co-seno do fator de inércia para o caso 2 (30 experimentos).

PSO	função objetivo					gerações para obter o mínimo da função objetivo				
	máximo	mínimo	médio	mediana	desvio padrão	máximo	mínimo	média	mediana	desvio padrão
(1)	71,8178	53,2847	60,3443	58,6528	5,8498	100	46	70	71	18
(2)	84,3854	22,5250	48,5841	42,0697	22,4900	96	42	69	66	19
(3)	70,5101	23,9729	44,8344	44,0335	15,5675	90	48	67	68	13
(4)	61,2619	15,8254	45,8977	46,4360	12,8982	99	38	73	77	19
(5)	79,1758	33,5594	57,9154	59,7018	15,1620	100	35	62	59	20
(6)	96,0888	23,1634	60,3026	62,0835	22,8206	99	40	73	80	21
(7)	80,4260	17,2251	52,8658	56,5581	22,0383	93	40	69	69	18
(8)	68,0831	37,5589	50,9932	47,3031	10,7512	100	46	77	77	18
(9)	69,6377	37,9858	53,2974	53,6688	10,5811	100	33	59	51	21
média	75,7096	29,4556	52,7817	52,2786	15,3510	97	41	69	69	19

Tabela 10: Estudo comparativo de resultados de otimização entre PSO, algoritmos genéticos (AGs), programação evolutiva (PE) e estratégia evolutiva (EE) com mecanismos de auto-adaptação.

caso 1(b)	função objetivo				
método de otimização	máximo	mínimo	médio	mediana	desvio padrão
PSO(9) – tabela 5	0,2430	0,0850	0,1661	0,1710	0,0520
AG	0,4071	0,1620	0,2293	0,2371	0,0681
PE	0,3272	0,0591	0,1899	0,1981	0,0701
EE	0,2617	0,0616	0,1829	0,1905	0,0829
caso 2	função objetivo				
método de otimização	máximo	mínimo	médio	mediana	desvio padrão
PSO(4) – tabela 9	61,2619	15,8254	45,8977	46,4360	12,8982
AG	92,1131	46,3641	70,6868	69,6558	12,5333
PE	113,1821	37,8441	73,2459	70,6492	26,1091
EE	87,7153	31,5241	62,9151	67,7126	15,1654