

Calibração das propriedades elásticas de uma placa ortótropa utilizando algoritmos genéticos

Andrés B. Cheung¹, Malton Lindquist², Carlito Calil Junior³

Trabalho recebido em 14/09/2004 e aprovado para publicação em 22/09/2004.

Resumo

Um dos problemas mais comuns na avaliação do comportamento de tabuleiros ortótropos é a obtenção dos parâmetros elásticos experimentais (E_x , E_y e G_{xy}). A partir destes parâmetros obtidos em laboratório, podem ser conhecidos os deslocamentos da placa. Porém, muitas vezes, os resultados obtidos são incompatíveis ou imprecisos em relação aos deslocamentos reais em campo. Um dos motivos desta imprecisão é a adoção de parâmetros elásticos baseados em dados experimentais obtidos em modelos reduzidos que não condizem com o comportamento real da placa devido a alguns efeitos de escala. Uma alternativa é a utilização do método inverso para a obtenção dos parâmetros elásticos através de métodos iterativos, principalmente quando a dimensão do espaço de parâmetros é grande. Neste caso, algumas dificuldades em relação à utilização destes métodos podem ser citadas: necessidade de derivar as funções deslocamento, grande número de parâmetros e a necessidade da verificação de convergência. Além disso, os métodos numéricos clássicos podem não garantir a obtenção do ótimo global. Portanto, o objetivo deste trabalho é utilizar Algoritmos Genéticos simples (AGs) para a obtenção de parâmetros elásticos a partir de dados experimentais obtidos em campo ou em protótipo e investigar a adequação de tal técnica no problema em questão. Uma das vantagens dos métodos estocásticos (AGs, Monte Carlo, Simulated Annealing etc...) é que as derivadas das funções deslocamento não necessitam ser calculadas. Os resultados mostram que o AGs são ferramentas computacionais eficientes para estimação de tais parâmetros, principalmente em problemas complexos envolvendo muitas variáveis e com espaço de solução de dimensão elevada. O modelo para avaliação dos deslocamentos foi desenvolvido a partir da solução por séries da equação de Huber sugerida por Cusens e Pama (1975).

Palavras-chave: calibração, placas ortótropas, Algoritmo Genético simples, parâmetros elásticos experimentais.

¹ Aluno de Doutorado em Engenharia de Estruturas no Departamento de Estruturas da Escola de Engenharia de São Carlos (EESC-USP). LaMEM-EESC-USP, Av. Trabalhador São Carlense 400, CEP: 13566-590, São Carlos, SP, Brasil. Tel: +55 16 3373-9369. E-mail: acheung@sc.usp.br

² Aluno de Doutorado em Engenharia de Estruturas no Departamento de Estruturas da Escola de Engenharia de São Carlos (EESC-USP). LaMEM-EESC-USP, Av. Trabalhador São Carlense 400, São Carlos, CEP: 13566-590, SP, Brasil. Tel: +55 16 3371-7260. E-mail: malton@sc.usp.br

³ Prof. Dr. Escola de Engenharia de São Carlos, Universidade de São Paulo/São Carlos (EESC-USP). LaMEM-EESC-USP, Av. Trabalhador São Carlense 400, CEP: 13566-590, São Carlos, SP, Brasil. Tel: +55 16 3373-9483. E-mail: calil@sc.usp.br

1. Introdução e objetivo

Algoritmos Genéticos (AGs) são métodos de busca estocástica que imitam matematicamente os mecanismos de evolução natural das espécies, compreendendo processos da genética das populações, sobrevivência e adaptação dos indivíduos (Gen and Cheng, 1996). Cabe destacar que os AGs são aceitáveis não só pela sua imitação aos sistemas naturais mas também porque são teoricamente providos de busca robusta nos espaços complexos.

Os AGs diferem das técnicas de busca convencionais, pois iniciam o processo gerando um conjunto inicial de soluções aleatoriamente. Cada vetor solução deste conjunto inicial é então melhorado a cada iteração pelos operadores característicos (operadores genéticos) e representam uma possível solução completa para o problema.

Os AGs tem sido utilizados na engenharia estrutural por diversos autores nas mais variáveis aplicações. Podem-se destacar os trabalhos de Jenkis (1991), Oliveira (1998), Lemonge (1999), Argolo (2000), Silva (2001), Borges (2002), Castilho (2003) e Olivieri (2004).

Um dos problemas mais comuns na avaliação do comportamento de tabuleiros ortótropos de madeira é a obtenção dos parâmetros elásticos experimentais (E_x , E_y , G_{xy} , ν_{xy}). Porém neste trabalho foi desconsiderado o efeito do Poisson por se tratar de análise de placas e seu efeito é pouco significativo como demonstrado por Veloso (1999). Desta maneira, os parâmetros teóricos podem ser conhecidos a partir dos deslocamentos da placa obtidos pela equação de placas ortótropas (Equação de Huber). Porém, muitas vezes os resultados teóricos são incompatíveis ou imprecisos em relação aos deslocamentos reais. Um dos motivos desta imprecisão é a adoção de parâmetros elásticos incorretos, baseados em dados experimentais obtidos em laboratório com ensaios em modelos.

Para diminuir estas discrepâncias numéricas entre os valores obtidos através de ensaios e os valores obtidos em tabuleiros reais é proposto o método de calibração minimizando as diferenças absolutas através dos mínimos quadrados. Para isso, é necessário resolver a equação da placa e obter o gradiente para utilização de métodos iterativos convencionais, e assim obter os parâmetros elásticos experimentais. Tais complexidades referem-se que para a obtenção dos deslocamentos da placa são necessários empregos de técnicas numéricas que em geral são de difícil obtenção do gradiente para a utilização em algoritmos de programação não-linear e ao grande número de parâmetros.

Desta forma, os AGs vêm se tornando uma das técnicas computacionais mais robustas e poderosas em todas as áreas do conhecimento. Descrições detalhadas da sistemática desta técnica e das vantagens apresentadas podem ser encontradas em literaturas especializadas como os livros texto de Goldberg (1989), Michalewicz (1992) e Gen and Cheng (1996).

Portanto, o objetivo deste trabalho é utilizar os AGs para a estimação de parâmetros elásticos de uma placa ortótropa através da calibração do modelo numérico com os resultados pseudo-experimentais.

2. Fundamentação teórica

2.1 Solução de placas ortótropas:

Para análise de placas ortótropas, é necessário encontrar a solução para a equação diferencial parcial não homogênea, deduzida por Huber (1914) apud Cusens and Pama (1975), chamada no meio técnico de “Equação de Huber”.

$$D_x \frac{\partial^4 w}{\partial x^4} + 2H \frac{\partial^4 w}{\partial x^2 \partial y^2} + D_y \frac{\partial^4 w}{\partial y^4} = p(x, y) \quad (1)$$

Sendo os parâmetros de rigidez relacionados com os parâmetros elásticos desprezando-se o coeficiente de Poisson, onde t é a espessura da placa.

$$2H = \frac{G_{xy} t^3}{6} \quad (2)$$

$$D_x = \frac{E_x t^3}{12} \quad (3)$$

$$D_y = \frac{E_y t^3}{12} \quad (4)$$

A solução dessa equação diferencial não homogênea de Huber, Equação (1), consiste na superposição de duas soluções:

$$w = w_k + w_p \quad (5)$$

onde w_k representa a solução da equação diferencial homogênea e w_p representa uma solução particular da equação diferencial não homogênea.

Um dos métodos para solução desta equação diferencial é utilizada a solução de Navier, que aproxima os carregamentos por dupla série de senos e que no caso de carregamentos pontuais é descrita por Cusens and Pama (1975).

$$p(x, y) = \sum_{n=1}^{\infty} H_n \sin(\alpha_n x) \quad (6)$$




Figura 1: Função típica para carregamento concentrado.

Lembrando a solução proposta por Levy-Nadai (eq.7) e utilizando as séries para o carregamento concentrado, tem-se:

$$H_n = \frac{2P}{L} \operatorname{sen}\left(\frac{n\pi\pi}{L}\right) \quad (7)$$

$$w = \frac{PL^3}{\pi^4 D_x b} \sum_{n=1}^{\infty} \frac{1}{n^4} \operatorname{sen}(\alpha_n c) \operatorname{sen}(\alpha_n x) K_1 \quad (8)$$




Figura 2: Tabuleiro com carregamentos distribuídos em pequenas áreas, CUSENS & PAMA (1975).

O deslocamento pode ser obtido pela integração da Eq. (8) em função da pequena área mostrada pela Figura 2.

$$p = \frac{P}{2u \cdot 2v} \quad (9)$$

$$w = \frac{PL^4}{uv\pi^5 D_x} \sum_{n=1}^{\infty} \frac{1}{n^5} \operatorname{sen}(\alpha_n c) \operatorname{sen}(\alpha_n u) \operatorname{sen}(\alpha_n x) K_1^* \quad (10)$$

$$K_1^* = \frac{1}{2b} \int_{Y1-V}^{Y1+V} K_1 dy \quad (11)$$

O coeficiente K_1^* é expresso conforme a geometria do carregamento, e foi deduzido por Cusens and Pama (1975) para todos os casos de tabuleiros ortótropos simplesmente apoiados.

Esta solução foi implementada no software OTB (Orthotropic Timber Bridges), ou ATM (Análise de Tabuleiros de Madeira), em português, desenvolvido na Escola de En-

genharia de São Carlos (Lindquist and Pigozzo, 2004), com soluções exatas em relação a soluções de placas no Ansys 5.5, elemento Shell 63.

2.2 Fundamentos dos Algoritmos Genéticos simples (AGs)

Os AGs possuem vários elementos que os caracterizam. Essas características podem ser utilizadas baseando-se em diferentes especificações, dependendo do problema a ser tratado. Nesta seção são descritos sucintamente alguns conceitos relacionados com os AGs, a fim de facilitar o entendimento deste trabalho.

2.2.1 População inicial

Um Algoritmo Genético começa com uma população inicial de indivíduos com as características representadas pelos cromossomos. O cromossomo é um vetor unidimensional (*string*) cujos valores (variáveis de decisão) representam características (genes) da possível solução do problema e podem ser codificadas através da representação binária ou real, entre outras. A codificação depende do problema que está sendo tratado, por exemplo, em problemas combinatoriais a codificação mais apropriada é a binária. Já em problemas que contemplam funções contínuas, a codificação real é a mais adequada. A partir dessa escolha inicial, os vetores soluções (indivíduos) são gerados aleatoriamente através de rotinas computacionais existentes nos compiladores. Cabe observar que, se uma pequena população for gerada, alguns locais no espaço de busca podem não estar sendo representados.

Os AGs diferem das técnicas de busca convencionais, pois iniciam o procedimento computacional gerando um conjunto inicial de soluções possíveis aleatoriamente. Este conjunto é denominado “população” (Figura 3). Vários conjuntos de soluções (populações) são produzidos ao longo do processo iterativo. Cada vetor solução (indivíduo) pertencente a estes conjuntos (população), intuitivamente denominado “cromossomo” e constitui uma representação completa da solução para o problema. Estes cromossomos tendem a evoluir gradativamente através de sucessivas iterações, produzindo novas “gerações” de indivíduos melhores, em termos de uma função de aptidão, esta função será definida na Seção 2.2.2.




Figura 3: Representação da população com seus indivíduos (cromossomos).

2.2.2 Função de aptidão

A avaliação da população é realizada pela função de aptidão, que representa uma medida que avalia o vetor solução (a qualidade de cada indivíduo na população) durante o processo de evolução. Seu valor servirá como referência (qualidade da resposta) na classificação dessas soluções, indicando a chance de alguns vetores solução estarem presentes na população da próxima geração. A classificação pode ser feita através de uma ordenação das soluções de forma decrescente ou crescente em relação às suas aptidões, representando, respectivamente, o problema de maximização ou minimização. Assim, para problemas de otimização a função de aptidão está intimamente ligada à função objetivo (da Silva 2002). Uma função objetivo é um modelo matemático que precisa ser maximizado ou minimizado, considerando um número finito de restrições ou condições (Sierksma 1996). Porém, os valores da função objetivo nem sempre são adequados para serem utilizados como valores de aptidão. Pois a função objetivo pode fornecer valores negativos ou fornecer valores muito próximos entre os indivíduos presentes na população. No caso de valores negativos, alguns métodos de seleção não funcionam, por exemplo, o Roda Roleta. Em se tratando de valores muito próximos entre os indivíduos pertencentes à população, aumenta-se a possibilidade de uma solução ruim se encontrar na próxima geração. Com isso, deve-se buscar outro procedimento de seleção, por exemplo, seleção por torneio ou aplicar algum procedimento de parametrização dado pela Eq. (12):

$$f_k = 2 \left(\frac{N_p - k}{N_p - 1} \right) \quad (12)$$

onde N_p é o tamanho da população e k é o índice do cromossomo na população e f_k é a função de aptidão. O tamanho da população indica o número de indivíduos em cada população, normalmente constante durante a evolução.

No método de Ordenamento Linear (Baker 1987) a aptidão é dada pela Eq. (13):

$$f_k = f_{\text{MIN}} + (f_{\text{MAX}} - f_{\text{MIN}}) \left(\frac{N_p - k}{N_p - 1} \right) \quad (13)$$

onde k é o índice do cromossomo na população em ordem decrescente do valor da função objetivo. Vale notar que deste modo a aptidão representa o número de filhos esperados do cromossomo e $f_{\text{MAX}} - f_{\text{MIN}}$ representa uma grande possibilidade de seleção (razão entre a maior aptidão e aptidão média, $f_{\text{max}}/\bar{f}$).

2.2.3 Seleção

O processo de seleção baseia-se no princípio de sobrevivência dos melhores indivíduos. Nesse processo, os indivíduos com melhor aptidão têm maior probabilidade de serem escolhidos para reprodução ou cruzamento. Em contrapartida, os indivíduos com bai-

xa aptidão podem não ser considerados para reprodução, conforme a pressão de seleção do esquema utilizado (da Silva 2002). Assim, o objetivo da seleção é escolher os indivíduos que servirão de base (pais) para o processo de reprodução. Existem várias formas de efetuar a seleção, podendo-se citar a seleção por posição (*rank*), seleção proporcional à aptidão (*roulette wheel*), seleção por torneio dentre outras (Lemonge 1999).

O método clássico proposto por Holland (1975), denominado seleção proporcional ou roda roleta, tem como idéia básica determinar a probabilidade de seleção para cada cromossomo proporcionalmente ao seu valor de aptidão. Para cada cromossomo k com avaliação f_k , onde a probabilidade de seleção P_k pode ser calculada conforme a Eq. (14).

$$P_k = \frac{f_k}{\sum_{k=1}^{N_p} f_k} \quad (14)$$

2.2.4 Cruzamento (crossover) e mutação

O processo de seleção não introduz novos indivíduos na população, apenas os chamados genitores, que servirão como “pais” para a nova geração, composta pelos “filhos”.

É na etapa de reprodução na qual o algoritmo tenta criar novas e melhores soluções (indivíduos mais aptos). Para isso, operadores genéticos são utilizados. Os principais são os operadores de Crossover e Mutação, descritos resumidamente a seguir (da Silva 2002).

O operador cruzamento ou recombinação é aplicado em pares de cromossomos retirados da população, para gerar seus descendentes. Cada um dos cromossomos pais tem sua cadeia de dados seccionada em uma posição aleatória, produzindo dois novos indivíduos (pares). Segundo Dejong (1975) deve-se escolher uma probabilidade de cruzamento igual para cada par, em geral entre 0,6 a 0,9.

Várias técnicas de recombinação são propostas na literatura, cruzamento uniforme, cruzamento médio, cruzamento baseado na média geométrica, cruzamento *BLX* – α (*Blended crossover*), cruzamento simples, cruzamento aritmético e cruzamento linear. Maiores detalhes podem ser obtidos em Deb (2001).

O operador de mutação é necessário para a introdução e manutenção da diversidade genética entre os novos indivíduos na população. Ele fornece, assim, meios para a introdução de novos indivíduos ou elementos na população, assegurando que a probabilidade de se chegar a qualquer ponto do espaço de busca seja zero, com o intuito de tentar contornar o problema de ótimos locais (da Silva 2002). Este operador é utilizado após a aplicação dos operadores de recombinação. No caso de codificação binária, o operador mutação efetua uma troca aleatoriamente no *bit*, de 1 para 0 ou de 0 para 1, na codificação real a troca aleatória respeita os limites de cada variável de decisão. Mutação uniforme, mutação não uniforme e mutação de deslocamento são algumas das técnicas de mutação propostas na literatura (Deb 2001).

O operador de mutação é aplicado aos indivíduos com uma probabilidade dada pela taxa de mutação. Geralmente se utiliza uma taxa de mutação pequena (como na genética natural), pois a mutação é um operador genético secundário (da Silva 2002).

Os operadores genéticos acima descritos são os fatores responsáveis pela evolução dos AGs e têm como finalidade principal a obtenção de conjuntos de soluções melhores (populações) através de sucessivas iterações (gerações). Goldberg (1989) estudando tais operadores, afirma que através do processo iterativo podem-se perder informações (características) relativas a solução ótima, desta forma o operador de mutação faz com que estas informações sejam novamente incorporadas no processo de busca.

2.2.5 Gerações seguintes

Determinada a primeira geração, o procedimento se repete até que o critério de parada seja satisfeito. Normalmente o critério de parada considera a convergência e número de geração. Quando uma dessas condições for satisfeita, tem-se a população final, que é o conjunto de possíveis soluções do sistema. A convergência consiste em verificar a proximidade da aptidão com um valor esperado. Fica a cargo do usuário estabelecer um limite entre o valor esperado e o valor de parada. Como alternativa ao teste convergência, é estabelecido também um número máximo de gerações que possam ser produzidas. Essa estratégia é utilizada como meio de garantir que o algoritmo não fique executando por um tempo muito longo, já que não se sabe quando ele irá (e se irá) convergir (da Silva 2002).

2.2.6 Implementação e aplicação dos AGs

Diversas são as possibilidades de implementação e aplicação dos AGs. Geralmente, os AGs seguem o procedimento apresentado na Figura (4).

2.2.7 Tipos de Algoritmos Genéticos simples (AGs)

Os AGs podem ser classificados em: geracional, geracional elitista e estacionário (*steady state*). Nos AGs geracionais, todas as soluções são avaliadas (funções de aptidão) e substituídas a cada iteração (geração). Nos AGs geracionais elitista, a estratégia de evolução do método garante que as melhores soluções de cada geração sejam preservadas para compor a próxima geração. Nos AGs estacionários (*steady state*), algumas soluções (por exemplo, duas soluções) são geradas inicialmente a mais que a dimensão da população total, previamente estipulada (N_p). Por exemplo, geram-se $N_p + 2$ soluções iniciais que são avaliadas e classificadas em ordem decrescente ao valor de suas respectivas funções de aptidão. Uma análise estatística é realizada nessa etapa, onde as melhores soluções são escolhidas e as duas piores soluções são descartadas. Depois disso, duas novas soluções são selecionadas e avaliadas para substituir os




Figura 4: Processo esquemático geral dos Algoritmos Genéticos convencionais (AGs).

vetores descartados e constituir novamente uma população com dimensão. A partir da segunda geração, a avaliação da função de aptidão, nos AGs estacionários, é realizada apenas para dois novos indivíduos e não em todos como nos AGs geracionais.

Com a finalidade de exemplificar a utilização dos AGs na determinação das propriedades elásticas da placa é apresentada a seguir a metodologia proposta.

2.3 Formulação do Problema

Para a calibração dos parâmetros elásticos é necessário um modelo estrutural baseado em solução de placas ortótropas. Neste trabalho foi utilizada solução de Navier por apresentar melhor custo computacional comparado com elementos finitos. Porém uma das desvantagens da solução em série é a falta de generalidade para outros tipos de vinculação. Como o objetivo principal foi à implementação da metodologia de calibração com a utilização de algoritmos genéticos, foi utilizada a solução descrita por Cusens and Pama (1975). Porém para encontrar os parâmetros elásticos é admitida que para uma configuração de deslocamentos real existe somente uma configuração de parâmetros elásticos. Assim o problema consiste basicamente em minimizar a Eq. (15) que é a norma euclidiana dos resíduos. Assim, quando a função apresentar o seu valor de mínimo, este valor corresponderá aos valores de parâmetros elásticos que produziram os resultados mais próximos dos resultados experimentais e, conseqüentemente, os verdadeiros valores dos parâmetros obtidos pelo ensaio.

$$\min \sum_{i=1}^n |w_t - w_e|^2 \quad (15)$$

sendo:

w_e : deslocamento medido no ensaio no ponto i ,

w_t : deslocamento obtido pela solução da equação diferencial com parâmetros elásticos gerados pelo algoritmo no ponto i .

3. Metodologia

AGs são métodos estocásticos, portanto há necessidade de se determinar os parâmetros de entrada do modelo com o qual a solução obtida seja mais acurada. Estes parâmetros são o tamanho da população (N_p), o número de gerações (N_{ger}), a probabilidade de recombinação (p_r), a probabilidade de mutação (p_m) e os dados experimentais (y_i), estes últimos definidos no item anterior. Uma análise de sensibilidade foi realizada com objetivo de verificar a influência da dimensão da população na solução ótima final e determinar qual o tamanho da população mais adequado ao problema, chegando-se ao valor de 150 indivíduos.

O número de gerações máximo foi considerado igual a 100. As probabilidades de cruzamento (crossover) e mutação foram 0,9 e 0,2, respectivamente, pois levavam a uma convergência mais rapidamente para o caso estudado.

A obtenção dos parâmetros elásticos é baseada em minimização dos resíduos expressa na Eq. (15). Para a comprovação da eficácia do algoritmo, foi realizada uma simulação numérica com parâmetros elásticos conhecidos.

Para simulação computacional foram introduzidos parâmetros elásticos conhecidos inicialmente para obtenção de deslocamentos. Assim, alteraram-se os parâmetros iniciais com o intuito da obtenção dos mesmos a partir dos deslocamentos obtidos inicialmente.




Figura 5: Fluxograma do funcionamento do programa.

3.1 Exemplo 1

Uma placa bi-apoiada, com 10 metros de vão, 5 metros de largura e 20 centímetros de espessura foi utilizada para a comprovação do processo inverso. Os parâmetros elásticos de verificação são os seguintes:

Tabela 1: Valor dos parâmetros elásticos iniciais.

E_x (kN/cm ²)	E_y (kN/cm ²)	G_{xy} (kN/cm ²)
2000	200	50

Foram aplicadas duas cargas de 75 kN, conforme a tabela a seguir.

Tabela 2: Posição dos carregamentos e deslocamentos iniciais.

	X (cm)	Y (cm)	Deslocamentos iniciais (cm)
1	500	-250	8,44049
2	500	0	4,78563
3	500	250	0,84888
Carregamentos			
P1	500	-200	75kN
P2	500	0	75kN




Figura 6: Carregamentos aplicados.

Para medida dos deslocamentos, foram escolhidos 3 pontos na seção transversal da placa mostrados na Figura 4. A Tabela 2 apresenta os deslocamentos obtidos no programa através dos parâmetros elásticos iniciais mostrados na Tabela 1.




Figura 7: Pontos com deslocamento considerado na otimização.

3.2 Exemplo 2

No exemplo 2, foram consideradas as cargas P1 e P2 atuando separadamente. Os deslocamentos para estes casos são apresentados na Tabela 3. Foi utilizada a metodologia de contra-prova, onde se consideram os deslocamentos a partir de duas condições distintas de carregamento obtendo-se assim mais informações de deslocamentos para os mesmos pontos de leitura. A função objetivo é calculada da mesma forma, porém considerando os dois casos de carregamento e obtendo os resíduos para cada situação.

Tabela 3: Posição dos carregamentos e deslocamentos iniciais.

		X (cm)	Y (cm)	Deslocamentos iniciais (cm)
P1	1	500	-250	6,61684
	2	500	0	2,03788
	3	500	250	-0,97477
P2	1	500	-250	1,82365
	2	500	0	2,75775
	3	500	250	1,82365

Após registrar os valores dos deslocamentos obtidos com os parâmetros elásticos iniciais, passou-se para a fase de otimização. Nesta fase foram considerados parâmetros elásticos imprecisos, para que o algoritmo genético encontrasse os parâmetros elásticos iniciais a partir dos deslocamentos mostrados nas Tabelas 2 e 3.

A região factível dos parâmetros elásticos para o teste de convergência é apresentada nas inequações abaixo.

$$1500 < E < 4500 \text{ kN/cm}^2 \quad (16)$$

$$135 < E_y < 450 \text{ kN/cm}^2 \quad (17)$$

$$35 < G_{xy} < 105 \text{ kN/cm}^2 \quad (18)$$

Foram utilizados, neste trabalho, diferentes tamanhos de população para o AGs considerado. Os resultados de tais simulações são apresentados nas Figuras 8 e 9. Observa-se que os tamanhos da população variaram no intervalo 50-150.

Tabela 4: Combinação dos parâmetros dos AGs.

Tipo	Parâmetros			
	População	Gerações	Recombinação	Mutação
1	50	100	0,9	0,2
2	100	100	0,9	0,2
3	150	100	0,9	0,2

4. Resultados

Os resultados obtidos na aplicação da metodologia sugerida para os dois exemplos mencionados são apresentados nesta seção. É importante ressaltar que os AGs foram utilizados como técnica de otimização para estimação dos parâmetros elásticos a partir da minimização da norma dos resíduos. O algoritmo genético utiliza o suporte computacional da biblioteca GALib (Wall 1999), escrita na linguagem C++.

Um código computacional foi implementado em linguagem C++, acoplado ao programa OTB, (Lindquist and Pigozzo, 2004), contemplando as funções da solução por séries de placas ortótropas, servindo como função objetivo dos AGs.

Foram feitas três simulações para cada caso, encontrando em cada uma os parâmetros elásticos otimizados. O erro é o resultado da raiz quadrada da Eq. (15).

Observando-se os resultados referentes aos dois problemas exemplo, nota-se que, conforme o tamanho da população aumenta, o número de gerações exigido para a convergência do método tende a ser menor.

Observa-se na Tabela 5, que os valores do módulo de elasticidade transversal mantiveram-se sempre aproximadamente 0,5 % maior que o valor exato para as três populações, porém, para os outros parâmetros, o erro foi praticamente nulo.

Já os resultados da Tabela 6, foram mais precisos para os três parâmetros, pois foi utilizada a metodologia de contra-prova, que fornece mais informações sobre o comportamento estrutural da placa ao programa, pois informa os deslocamentos em duas situações distintas.

Tabela 5: Resultados do exemplo numérico 1.

Parâmetros	Exato	Resultados calibrados		
		Tipo 1	Tipo 2	Tipo 3
Ex	2000	2000.064	2000.965	2000.064
Ey	200	201.138	201.134	201.138
Gxy	50	50.000	50.000	50.000
Erro	0	1.25E-06	2.34E-06	1.75E-06
Posição		Deslocamentos		
1	8.44048	8.44047	8.44047	8.44047
2	4.78563	4.78583	4.78583	4.78583
3	0.844048	0.84889	0.84889	0.84889




Figura 8: Convergência da função objetivo para o exemplo 1.

Tabela 6: Resultados do exemplo numérico 2.

Parâmetros		Exato	Resultados calibrados		
			Tipo 1	Tipo 2	Tipo 3
Ex		2000	2000.066	2000.067	2000.477
Ey		200	200.066	200.066	200.115
Gxy		50	49.997	49.997	49.925
Erro		0	4.61e-04	4.63E-04	2.18E-03
Posição		Deslocamentos			
Condição P1	1	6.61684	6.61665	6.61663	6.61746
	2	2.03788	2.03787	2.03787	2.03738
	3	-0.97477	-0.97494	-0.97493	-0.97666
Condição P2	1	1.82365	1.82368	1.82368	1.82316
	2	2.74775	2.74833	2.74833	2.74785
	3	1.82365	1.82368	1.82368	1.82316




Figura 9: Convergência da função objetivo para o exemplo 2.

O erro encontrado no exemplo 2, embora maior que no exemplo 1, não implica que o resultado tenha sido mais impreciso, pois envolve a soma de seis comparações entre os dados teóricos e pseudo-experimentais com dois estados de carregamento distintos, enquanto o exemplo 1 envolve apenas 3 leituras de deslocamento para um estado de carregamento. Portanto, mesmo com valor absoluto do erro maior, o exemplo 2 tem resultados mais exatos que o exemplo 1.

O gráfico de convergência mostra que, devido ao algoritmo genético ser um método estocástico, pode-se ter descontinuidades na função objetivo. Também é possível observar que, com 50 gerações, o método obteve valores precisos, sem haver a necessidade de se realizarem mais gerações. Porém, mesmo com a impossibilidade de visualização gráfica, houve melhora na função objetivo após a quinquagésima geração.

Nota-se que o objetivo do trabalho foi alcançado, visto que a exatidão do resultado depende apenas do número de iterações que são verificadas pelo critério de convergência. Com o número de gerações tendendo a infinito, os resultados tenderão aos valores exatos, pagando-se um preço computacional por este grande número de gerações. Para as aplicações práticas, a precisão encontrada é satisfatória, podendo-se obter resultados satisfatórios com menor número de gerações do que o utilizado neste trabalho.

Porém são necessárias verificações experimentais antes de concluir que o modelo funcionará satisfatoriamente bem em casos reais.

5. Conclusões

O objetivo deste trabalho foi utilizar os AGs para a estimação de parâmetros elásticos de uma placa ortótropa através da calibração do modelo numérico com os resultados experimentais. O trabalho permitiu avaliar os parâmetros elásticos de tabuleiros ortótropos não dependendo somente de análise de modelos reduzidos, ou de ensaios de laboratório como os de Tsai (1965), ou de Davalos & Brokaw (1992), que são susceptíveis a erros devido a efeitos de escala e hipóteses simplificadoras. O problema foi abordado de forma alternativa através do processo inverso utilizando os Algoritmos Genéticos para minimização da função objetivo.

Esta metodologia pode ter uma aplicação prática que é a verificação da perda de rigidez de pontes ao longo do tempo, encontrando uma possível necessidade de reprotensão em pontes protendidas de madeira, ou de reforço em pontes ortótropas com problemas estruturais.

A partir de uma simples prova de carga com três pontos de leitura, os parâmetros elásticos podem ser encontrados, unicamente sujeita à acuidade dos dados de leitura encontrados.

Este trabalho permitiu demonstrar a aplicação da sistemática de algoritmos genéticos (AGs) no problema de estimação de parâmetros elásticos. O procedimento foi ilustrado nos problemas exemplo, com solução conhecida, como forma de verificar a adequação e desempenho da técnica no problema proposto.

Portanto, pode-se afirmar que os AGs podem ser técnicas computacionais adequadas para estimar parâmetros elásticos de placas ortótropas através de ensaio em estruturas existentes. Os AGs se apresentaram robustos em relação ao problema e demonstraram que são ferramentas computacionais eficientes.

Referências

- Argolo, W. P. (2000). *Otimização de Seções de Concreto Armado Submetida a Flexo-Compressão Reta Utilizando Algoritmos Genéticos*. Dissertação (Mestrado em Engenharia Civil)- COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- Baker, J. (1987). Reducing Bias and Inefficiency in the Selection Algorithm. In: Grefenstette, J. (ed.). *Proceedings of the Second International Conference on Genetic Algorithms and their Applications*, New Jersey: Hillsdale: Lawrence Erlbaum Association. p. 14-21.
- Borges, F. P. S. (2002) *Otimização Via AG do Processo Construtivo de Estruturas de Concreto Submetidos à Retração Restringida Tendo em Vista a Fissuração nas Primeiras Idades*, Dissertação (Mestrado em Engenharia Civil)- COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- Castilho, V. C. (2003). *Otimização de Componentes de Concreto Pré-Moldado Protendidos mediante Algoritmos Genéticos*. Tese (Doutorado em Engenharia de Estruturas)- EESC/USP, São Carlos, SP, Brasil.
- Cusens, A.R. and Pama, R.P. (1975). *Bridge Deck Analysis*. Editora John Wiley Sons, London, 278 p.
- Davalos, J. F. and Brokaw, J. T. (1992). System stiffness and strength properties of stress-laminated timber bridge decks. *1992 International Winter Meeting*. The American Society of Agricultural Engineers.
- Deb, K. (2001). *Multi-Objective Using Evolutionary Algorithms*. John Wiley & Sons, Ltd.
- Dejong, K. (1975). *The Analysis and Behavior of a Class of Genetic Adaptive Systems*. PhD dissertation, University of Michigan.
- Engineering Statistics Handbook (2002). NIST/SEMATECH and Handbook of Statistical Methods, Sematech, Inc. <http://www.itl.nist.gov/div898/handbook/>, date. Copyright.
- Gen, N. and Cheng, R. (1996). *Genetic Algorithms and Engineering Design*. John Wiley & Sons, INC.
- Goldberg, D.E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, Reading, Massachusetts, London, 278 p.
- Jenkis, W. M. (1991). Steady-State towards structural optimization via the algorithm genetic. *Computers & Structures*, v.40, n.5, p.1321-1327.
- Lemonge, A.C. de C. (1999). *Aplicação de Algoritmos Genéticos em Otimização Estrutural*. Tese (Doutorado), Universidade Federal do Rio de Janeiro – RJ, 202 p.
- Lemonge, A. C. C. (1999). *Aplicação de algoritmos genéticos em otimização estrutural*. Tese (Doutorado em Engenharia Civil)- COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- Lindquist, M.; Pigozzo, J. C.; Calil, C. and Dias, A. A. (2004). Análise numérica de uma ponte mista madeira-concreto através da teoria de placa equivalente. *Jornadas Sulamericanas de Engenharia Estrutural*, Mendoza, ARG.

- Michalewicz, Z. (1992). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer-Verlag, New York, N.Y.
- Oliveira, S. R. (1998). *O algoritmo genético na otimização do projeto estrutural de embarcações*. Tese (Doutorado em Engenharia de Estruturas)- Escola de Politécnica da Universidade de São Paulo, São Paulo.
- Olivieri, B. P. (2004). *Otimização do Projeto de Pontes Protendidas Pré-Moldadas pelo Método dos Algoritmos Genéticos* Dissertação (Mestrado em Engenharia Civil)- COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- Sierksma, G. (1996). *Linear and Integer Programming: Theory and Practice*. Marcel Dekker Inc., New York, N.Y.
- Silva, E. E. (2001). *Otimização de estruturas de concreto armado utilizando algoritmos genéticos*. Dissertação (Mestrado em Engenharia de Estruturas)- Escola de Politécnica da Universidade de São Paulo, São Paulo.
- Tsai, S. W. (1965). Experimental Determination of the Elastic Behavior of Orthotropic Plates. *Journal of Engineering for Industry*, Transactions American Society of Mechanical Engineering 315.
- Veloso, L.A.C.M. (1999). *Estudo do comportamento das placas de Madeira protendida*. São Paulo. Dissertação (Mestrado em Engenharia Civil)- POLI/USP, São Paulo, SP, Brasil.
- Wall, M. (1999). *Galib: A C++ Library of Genetic Algorithm Components (version 2.4)*. Mechanical Engineering Department, Massachusetts Institute of Technology.
- Whitley, D. (1994). A genetic Algorithm Tutorial. *Statistic and Computing*, vol. 4, p. 65-85.

Orthotropic plates elastic properties calibration using genetic algorithms

Abstract

One of the problems in evaluating orthotropic decks is obtaining experimental elastic moduli (E_x , E_y and G_{xy}). An orthotropic plate computer model can analyze the deck behavior via laboratory-achieved elastic moduli. However, laboratory results are repeatedly unsuited or inaccurate when applied to compare real field deck performance. One of the reasons to this imprecision is the adoption of elastic parameters based on experimental data obtained in reduced scale models that don't match with the real behavior of the plate due to some scale effects. An alternative to this analysis can be found using an inverse method with the intention of obtaining the elastic properties from iterative methods. This is more useful when there is a large space parameters dimension. In this case, some difficulties are found because it can be necessary to derivate deflection functions, and the method would eventually demands convergence. Besides, classic numeric methods cannot guarantee the obtaining of the global minimum. Therefore, the objective of this work is to use simple Genetic Algorithms (SGA) to obtain elastic properties using the field performance of orthotropic decks as input data. One of the advantages of SGA remains in the fact that they don't need deflection function derivation. The results demonstrate that SGA are efficient computer tools when they are used to estimate elastic properties. The model used to evaluate deflections was developed from the Cusens and Pama (1975) series solution for Huber's orthotropic plates equation.

1. Objective

Genetic algorithms (GAs) are stochastic search methods that emulate natural species evolution mathematically. They create genetic population processes, including survival and individual adaptation (Gen and Cheng 1996).

The objective of this work is to use AGs to estimate orthotropic plates elastic parameters through numerical model calibration by experimental results.

2. Background

In order to analyze orthotropic plates the series solution for the equation partial differential non-homogeneous equation, known as Huber's Equation (Huber 1914 apud Cusens and Pama 1975), was used, Eq. (1).

AGs contain several elements that characterize them, such as initial population, objective function, natural selection, crossover, mutation and generation number. Those characteristics can be used based on different applications, depending on the problem to be solved. A general outline of the process is illustrated Figure 4.

The problem considered in this research consists, basically, of minimizing Eq. (15), which is the residue Euclidian norm. Consequently, when Eq. (12) presents its minimum value, this value corresponds to the elastic parameters that produced closest results to the experimental deflections and, consequently, the actual values of the parameters obtained by the essay.

3. Evaluation methodology

With the purpose of testing the proposed methodology, simulations were done to proof the effectiveness of the employed method using two examples. The genetic operators used in the simulations are shown in Table 4. They follow the recommendation of researchers (da Silva 2002). In the convergence verification, the algorithm stop criterion was the maximum number of generations, 100 in this study. Three different populations were evaluated to test its influence in convergence.

Initially, acknowledged elastic parameters were introduced to obtain exact displacements. Afterward, some imprecise elastic parameters were considered, leaving to the computer the task of obtaining the exact values from the exact displacements, minimizing the residue Euclidian norm, Eq. (15).

4. Results

It can be observed in Table 5 that the values of the transverse module were approximately 0,5% bigger than the exact value for the three populations. However, for the other parameters, the error was practically null.

The results in Table 6 show more accurate parameters. It is explained by the fact that, with two load tests considered in the same optimization, more information about the plate behavior were given to the software, because it considered displacements in two different circumstances, that means, a better result was achieve.

5. Conclusions

The objective of this work was the use of GAs to estimate elastic parameters of an orthotropic plate using type experimental results numeric model calibration. This work showed how to evaluate elastic parameters of orthotropic plates without reduced plate models analysis, and without laboratory experiments such as Tsai (1965), and Davalos and Brokaw (1992). These laboratory plate tests are susceptible to errors due to scale effects and simplified hypotheses. The problem can be considered in an alternative way,

through the inverse process using the Genetic Algorithms to minimize the objective function with precise results.

This methodology has a practical application in verifying bridges stiffness loss during its lifetime. It may be possible to advice a restress in pre-stressed timber bridges decks, or locate orthotropic bridges with structural problems.

Using a static load test with three deflection points, elastic parameters can be found accurately. The value of result is only related to the sharpness of the experimental data considered.

This paper demonstrated a genetic algorithms (GAs) application in the problem of estimating elastic moduli. The procedure was illustrated in the examples, with known solution, verifying the adaptation and use of the technique in the proposed problem.

Therefore, it can be affirmed that GAs are an appropriate computational technique to estimate orthotropic plates elastic moduli through load tests in real structures. GAs were useful when used in the application proposed in this work and demonstrated they are efficient tools in engineering practical problems.