



ALGORITMOS GENÉTICOS APLICADOS AO PLANEJAMENTO DA TRAJETÓRIA ÓTIMA DE ROBÔS MANIPULADORES

Sezimária F. P. Saramago

Faculdade de Matemática - Universidade Federal de Uberlândia
Campus Santa Mônica- CEP 38400-902 Uberlândia, MG, Brasil
e-mail: saramago @ ufu.br

Resumo. *Algoritmo genético é um subconjunto dos algoritmos evolutivos que modelam processos biológicos visando otimizar funções objetivo altamente complexas. Este algoritmo permite que uma população composta de muitos indivíduos possa evoluir obedecendo as regras de seleção especificadas para um estado que maximiza a "aptidão", quer dizer, minimiza a função custo. Robôs imitam o movimento biológico e o algoritmo genético imita a sobrevivência biológica. Os dois tópicos parecem ter uma perfeita combinação e muitas pesquisas fazem esta conexão. A trajetória do robô descreve a posição, a orientação, a velocidade, e a aceleração de cada componentes de robô como uma função de tempo. Quando são impostos processos repetitivos, é possível desenvolver uma metodologia para mover o robô manipulador ao longo de um caminho geométrico que evite os obstáculos. Isto pode ser alcançado com custo de mínimo por técnicas de otimização. Foram usadas funções de penalidade para evitar que as restrições fossem violadas durante o processo de minimização. A natureza das restrições dos obstáculos são tais que, em geral, vários mínimos locais existem e podem ser observados ao longo do procedimento numérico. Algoritmos genéticos são técnicas randômicas capazes de saltar os mínimos locais, particularmente no caso onde falham as técnicas tradicionais. Neste trabalho foi calculada a trajetória ótima de um manipulador plano com três graus de liberdade e considerada a presença dos obstáculos no espaço de trabalho do robô. São discutidas as características computacionais básicas e apresentados resultados de exemplos numéricos para mostrar a eficiência da metodologia proposta.*

Palavras-chave: *Otimização, Algoritmo Genético, Robô Manipulador, Planejamento de Trajetória*

1. INTRODUÇÃO

As técnicas de otimização são conhecidas a bem mais de um século, sendo utilizadas na física e na geometria, servindo-se de ferramentas associadas às equações diferenciais do Cálculo Variacional. Foi entretanto nos últimos 30 anos que o uso de técnicas de otimização popularizou-se grandemente, coincidindo naturalmente com o desenvolvimento da computação digital. Técnicas clássicas de otimização são confiáveis e possuem aplicações nos mais diferentes campos de engenharia e de outras ciências. Os métodos de otimização clássica podem, de maneira bastante geral, dividir-se em métodos diretos e métodos sequenciais. Os primeiros exploram os limites impostos pelas restrições durante todo o processo de minimização e utilizam variáveis "de folga" para garantir que tais restrições não são violadas. Os métodos sequenciais, através de uma função pseudo-objetivo, permitem obter o projeto restrito ótimo pela solução sequencial do problema sem restrição. Em Vanderplaats (1984) encontra-se uma comparação entre estas duas abordagens e também uma bibliografia básica sobre o tema. As técnicas clássicas de otimização podem apresentar algumas dificuldades numéricas e problemas de robustez relacionados com: a falta de

continuidade das funções a serem otimizadas ou de suas restrições, multimodalidade, existência de ruídos nas funções, existência de mínimos ou máximos locais, etc.

Existe uma clara tendência em se buscar modelos encontrados na natureza para se representar processos que podem ser chamados de “inteligentes”. Tudo indica que os processos naturais relacionados aos seres vivos são muito bem concebidos e adaptam-se ao mundo do engenheiro trazendo resultados surpreendentes em muitas aplicações. Recentemente métodos associados aos fenômenos naturais tem surgido, propondo alternativas às dificuldades mencionadas, tais como os Algoritmos Genéticos, redes Neurais e o método Simulated Annealing que faz uma analogia com o processo de recozimento dos materiais físicos (Kirkpatrick et al., 1983 e Saramago et al, 1999).

Algoritmos Genéticos (AG) baseiam-se no processo de seleção natural da luta pela vida. Nos últimos anos várias pesquisas estão sendo desenvolvidas utilizando Algoritmos Genéticos. Podemos citar o trabalho de Chen et al. (2000) que utiliza um algoritmo híbrido com rede Petri e AG para modelar, programar e avaliar o desempenho do processo de fabricação de bolachas wafer. Steffen et al. (2000) aplicam duas técnicas passivas para a redução de vibrações em sistemas mecânicos e utilizam AG para determinar o projeto ótimo associado com o comportamento dinâmico em determinadas faixas de frequência pré-selecionadas. O projeto de um novo robô paralelo Haptic 6-dof é apresentado por Lee et al. (2001) no qual a solução ótima foi encontrada usando AG, obtendo-se um novo mecanismo leve e com um grande espaço de trabalho. A utilização de AG para calibrar máquinas fotográficas é proposta por Zhang and Ji (2001), o desempenho alcançado é excelente em termos de convergência, precisão e robustez. Thanapandi et al. (2001) empregam algoritmos genéticos para obter uma solução ótima para o problema de gerar a seqüência de dobras em chapas metálicas e também a seleção de ferramentas. Os exemplos citados ilustram a aplicação de AG em diferentes campos da engenharia moderna.

A motivação para esta pesquisa é o estudo dos Algoritmos Genéticos, visando a compreensão do mesmo, sua programação e aplicação a robótica. Como ilustração, apresenta-se o cálculo da trajetória ótima de um manipulador plano com três graus de liberdade, considerando-se a presença de obstáculos no espaço de trabalho do robô e portanto trabalhando-se com problemas restritos. São discutidas as características computacionais básicas e resultados de exemplos numéricos são apresentados para mostrar a eficiência da metodologia proposta.

2. FORMULAÇÃO DO PROBLEMA

Este trabalho procura modelar situações práticas onde deseja-se movimentar o efetuador do robô manipulador entre dois pontos conhecidos, evitando a colisão com obstáculos. Isto pode ocorrer, por exemplo, durante as operações de montagem ou transporte de objetos.

O modelo do robô é baseado nos parâmetros de Denavit-Hartenberg para sua representação e utiliza-se a mecânica Lagrangeana para obter as equações de movimento. Aplica-se B-splines cúbicas uniformes para solucionar o problema de planejamento de trajetórias ótimas, pois permitem o controle do grau de continuidade das juntas e como situam-se dentro de uma casca convexa, facilitam o refinamento da trajetória e o teste para evitar colisões com obstáculos. Seja um manipulador com n graus de liberdade (g.d.l.), consideremos que j representa as juntas e m representa os nós uniformemente espaçados usados para construir as splines cúbicas. O modelo da trajetória (Saramago and Steffen, 2001) considera os pontos iniciais e finais (P_0 e P_m). Para o tempo total de percurso T , considerando B-splines cúbicas uniformes com m nós e coeficientes C_j^i , escreve-se a trajetória $q_i(t)$ como :

$$q_i(t) = \sum_{j=0}^{m-1} q_j^i(t), \quad i=1, \dots, n, \quad (1)$$

$$q_j^i(t) = C_{j-3}^i b_{-3}(t) + C_{j-2}^i b_{-2}(t) + C_{j-1}^i b_{-1}(t) + C_{j-0}^i b_{-0}(t) \quad (2)$$

O problema geral de otimização é definido da seguinte forma: minimizar um funcional $F(x)$, chamado de função objetivo, sujeito a m_h restrições de igualdade $h(x)$ e a m_g restrições de desigualdade $g(x)$. Tem-se N variáveis de projeto, ou variáveis de decisão, que compõem o vetor x , estando estas variáveis sujeitas a restrições laterais que limitam os valores máximos (x^u) e mínimos (x^l) admitidos para as variáveis de projeto.

Seja a função objetivo F definida como uma medida da potência mecânica total dos atuadores. Considerando, as forças generalizadas u_i e as velocidades de junta como a derivada no tempo de q_i , o problema de otimização é dado por:

$$\text{Minimizar } F = \int_0^T \sum_{i=1}^{m-1} (u_i(t) \dot{q}_i(t))^2 dt \quad (3)$$

$$\begin{aligned} \text{Sujeito a } \quad & \max |q_{ji}(t)| \leq QC_j & \max |\dot{q}_{ji}(t)| \leq VC_j & \max |\ddot{q}_{ji}(t)| \leq WC_j \\ & \max |J_{ji}(t)| \leq JC_j & \max |u_{ji}(t)| \leq UC_j & d_{lq}(t) \leq 0 \\ & \text{para } j=1,2,\dots,n \text{ e } i=1,2,\dots,m-1 \end{aligned} \quad (4)$$

onde, QC_j é a restrição do angulo das juntas, VC_j é a restrição de velocidade, WC_j é a restrição de aceleração, JC_j é a restrição de jerk (variação da aceleração), UC_j é a restrição de força/torque para a junta j . Ao problema de controle ótimo adiciona-se restrições especiais $d_{lq}(t)$ relacionadas com a distância aos obstáculos.

A força generalizada u_i é dada por Saramago e Steffen (1999):

$$u_i = \sum_{j=1}^n D_{ij} \ddot{q}_j + \sum_{j=1}^n \sum_{k=1}^n C_{ijk} \dot{q}_j \dot{q}_k + G_i \quad (5)$$

onde, D_{ij} é a matriz de inércia do sistema, C_{ij} é a matriz de Coriolis e força centrífuga e G_i G_i é o vetor dos efeitos da gravidade.

Quando m nós são utilizados para construir as splines, as Eqs. (1) e (2) resultam em $n(m+2)$ coeficientes C_j^i a serem determinados, que representam as variáveis de projeto do problema de otimização. A estimativa inicial para estes coeficientes pode ser obtida através da interpolação linear partindo dos pontos dados P_o e P_m .

3. ALGORITMOS GENÉTICOS

Os estudos de métodos heurísticos, com busca randômica controlada por critérios probabilísticos, reaparecem como uma forte tendência nos últimos anos, principalmente devido ao avanço dos recursos computacionais. Dentro da chamada computação evolucionária, que engloba um número crescente de paradigmas e métodos, os Algoritmos Genéticos (AGs) são considerados um dos mais importantes. Estes métodos tem sido utilizados na solução de problemas de otimização nos quais a função objetivo não possui as propriedades de continuidade, diferenciabilidade ou não satisfazem as condições de Lipschitz para todo o domínio de interesse. Além disso, na aplicação dos métodos de otimização tradicionais, baseados em gradiente, torna-se evidente que para otimização de sistemas complexos, os algoritmos são freqüentemente “presos” em mínimos locais e métodos mais sofisticados são necessários para “escapar destas armadilhas”.

Algoritmos Genéticos são métodos computacionais de busca baseados nos mecanismos de evolução natural e na genética apresentados por Goldeberg(1989). Em AGs, uma população de possíveis soluções para o problema em questão evolui de acordo com operadores probabilísticos, de modo que há uma tendência de que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo continua. Os algoritmos genéticos podem ser

entendidos, de acordo com a definição acima, como sendo um processo de busca randômica direcionada (Kirkpatrick et al., 1983 e Michalewicz, 1996).

Dessa forma, à semelhança da evolução na busca pelo mais adaptado, ao longo de gerações sucessivas, espera-se ir melhorando as soluções encontradas, até chegar-se ao ótimo. Um algoritmo genético simples contém basicamente três operações: seleção, cruzamento e mutação. Geralmente a população inicial de K indivíduos é gerada de forma aleatória ou através de algum processo heurístico. Como na genética natural, não há evolução sem variedade e, por esta razão, é importante que os indivíduos tenham diferentes graus de adaptação ao ambiente em que vivem. Isto significa que a população inicial cubra da melhor forma possível o espaço de busca.

O operador *seleção* gera uma população temporária de K indivíduos considerando a probabilidade proporcional à adequabilidade relativa de cada indivíduo na população. Os indivíduos com baixa adequabilidade terão mais chance de desaparecerem. O operador *cruzamento* trabalha no sentido de selecionar dois indivíduos que vão trocar material genético entre si. Trata-se também de um processo aleatório que ocorre com probabilidade fixada pelo usuário. A *mutação* trata, como na natureza, de um evento de rara ocorrência. Sua finalidade é garantir que material genético importante não seja irremediavelmente perdido. O processo é encerrado ao se limitar o número máximo de gerações ou através do conceito de estagnação, ou seja, quando após várias iterações consecutivas, não se observa nenhuma melhora na população. Esta metodologia tem grande potencial para a solução de problemas de otimização, incluindo aí os problemas inversos.

Um pseudocódigo genérico capaz de englobar a maioria dos AG existentes é mostrado a seguir.

algoritmo genérico AG

Definir: parâmetros (n variáveis de projeto) : $x_i^l < x_i < x_i^u$, $i=1, \dots, N$

Função objetivo: $F(x_i)$

inicialize a população

avaliar K indivíduos da população

repita

selecione indivíduos para reprodução

aplique operadores de cruzamento e mutação

avaliar indivíduos na população

selecione indivíduos para sobreviver

até que critério de parada satisfeito

fim.

Nos algoritmos genéticos com codificação binária, os indivíduos são representados genotipicamente por vetores de dígitos binários, onde cada elemento de um vetor denota a presença (1) ou ausência (0) de uma determinada característica: o seu genótipo. Os elementos podem ser combinados formando as características reais do indivíduo, ou seu fenótipo (Davis, 1991 e Mitchell, 1994). A representação binária dos cromossomos é a representação adotada na maioria das implementações, pois facilita os processos de seleção e reprodução dos indivíduos (Haupt, 1998).

Neste trabalho o programa GAOT – The Genetic Algorithm Optimization Toolbox for Matlab5 foi utilizado. As características básicas deste programa são apresentadas por Houck et al. (1995). O programa de análise desenvolvido pela autora, para o cálculo da potência mecânica dos atuadores ao se mover o robô manipulador e também para gerar as trajetórias, foi acoplado ao programa de otimização.

3.1. Problemas de otimização com restrição

A manipulação de restrições nos programas de Algoritmos Genéticos torna-se difícil e são poucas as publicações que trata de problemas restritos. Uma primeira tentativa seria a rejeição dos indivíduos não viáveis, sendo bastante eficiente, mas torna o processo extremamente lento. Neste

caso, para cada novo indivíduo, verifica-se se as restrições são satisfeitas, caso necessário gera-se um novo vetor de variáveis de projeto.

Uma segunda metodologia utiliza o conceito de função de penalidade, bastante comum nos algoritmos sequenciais (Vanderplaats, 1984). Nesta técnica, os problemas com restrição são transformados em problemas irrestritos, adicionando-se uma função de penalidade $P(x)$ à função objetivo original e definindo-se uma nova função objetivo $\phi(x)$. Esta função pseudo-objetivo é penalizada, segundo um fator r_p , cada vez que encontra-se uma restrição ativa:

$$\begin{aligned} \mathbf{f}(x) &= F(x) + r_p P(x) \\ P(x) &= \left[\sum_{i=1}^{m_h} [h_i(x)]^2 + \sum_{i=1}^{m_g} \{\max[0, g_i(x)]\}^2 \right] \end{aligned} \quad (6)$$

onde $P(x)$ é a função de penalidade; g_i são as restrições de desigualdade; h_k são as restrições de igualdade; e o escalar r_p é o fator que quantifica a magnitude da penalidade.

4. APLICAÇÃO NUMÉRICA

Apresenta-se uma aplicação numérica para um manipulador plano com 3 juntas rotativas, conforme Fig. 1. Sejam os pontos inicial $P_o = [-0,4 \ -0,5 \ -0,6]^T$ e final $P_m = [0,8 \ 0,5 \ 0,6]^T$, dados em radianos. Assume-se que o robô está em repouso no início e no final da trajetória. As restrições são apresentadas na Tab. (1). Para a transformação do problema restrito em irrestrito utilizou-se um fator de penalidade $r_p = 10$.

Na aplicação de Algoritmos Genéticos considerou-se uma população com 80 indivíduos. A população inicial foi estimada partindo-se de uma trajetória inicial linear utilizando-se os pontos P_o e P_m dados acima.




Figura 1 - Robô manipulador com 3 g.d.l. e os obstáculos presentes no espaço de trabalho.

Considera-se os obstáculos A e B , como paredes obstruindo apenas o movimento da última junta. Assim, as restrições para evitar colisões com as paredes devem obedecer as equações:

$$l_1 \cos(q_1) + l_2 \cos(q_1 + q_2) + l_3 \cos(q_1 + q_2 + q_3) - 0,85 \leq 0 \quad (7)$$

$$l_1 \sin(q_1) + l_2 \sin(q_1 + q_2) + l_3 \sin(q_1 + q_2 + q_3) - 0,85 \leq 0 \quad (8)$$

Partindo de um tempo inicial $T=1,5s$ e uma potência mecânica de $F=268,6$ Nm, obteve-se o valor ótimo para a potência $F_{otim} = 42,6$ Nm. Apresentando, portanto, uma redução da potência mecânica dos atuadores de 15,9% do valor inicial, o que representa uma grande economia de energia.

Tabela 1 - Restrições para o manipulador com 3 g.d.l

	junta 1	junta 2	junta 3
VC (rd/s)	20	20	20
WC (rd/s ²)	60	60	60
JC (rd/s ³)	250	250	250
UC (Nm)	100	50	20




Figura 2 – Exemplo numérico para a trajetória do manipulador plano representado na Fig. 1:
 a) trajetória inicial; b) trajetória ótima

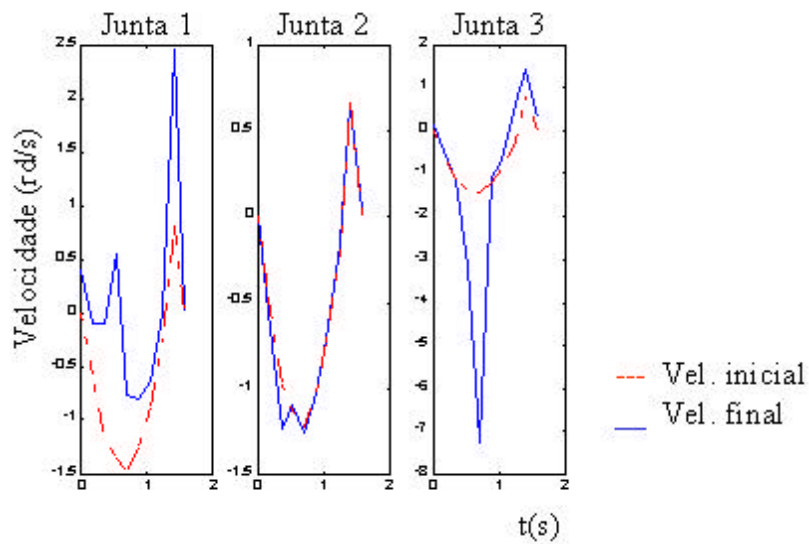


Figura 3 – Resultados para a trajetória ótima da Fig. 2b) em termos da velocidade (coordenadas de junta) ao longo do tempo.

A trajetória utilizada como partida para o programa de otimização e o resultado encontrado para a trajetória ótima são apresentados na Fig (2). Conforme pode ser observado nesta figura, o caminho ótimo evita a colisão com os obstáculos. Além disso, todas as restrições foram obedecidas, mostrando desta forma ser possível aplicar Algoritmos Genéticos a problemas restritos, utilizando o conceito de funções de penalidade. Para ilustrar este resultado, as Figs. (3) a (5) apresentam os gráficos da velocidade, aceleração e torque, considerando os valores iniciais e os valores ótimos ao longo do tempo. Nas Figs. (3) e (4) verifica-se que a velocidade e aceleração sofreram maior variação nas juntas 1 e 3, sendo que para a junta 2 estas grandezas cinemáticas quase não foram alteradas.

Na Fig. (5) observa-se uma significativa redução dos valores dos torques, principalmente em relação à junta 1. Tal resultado explica o resultado obtido pelo programa de otimização para a potência mecânica dos atuadores, conforme discutido anteriormente.

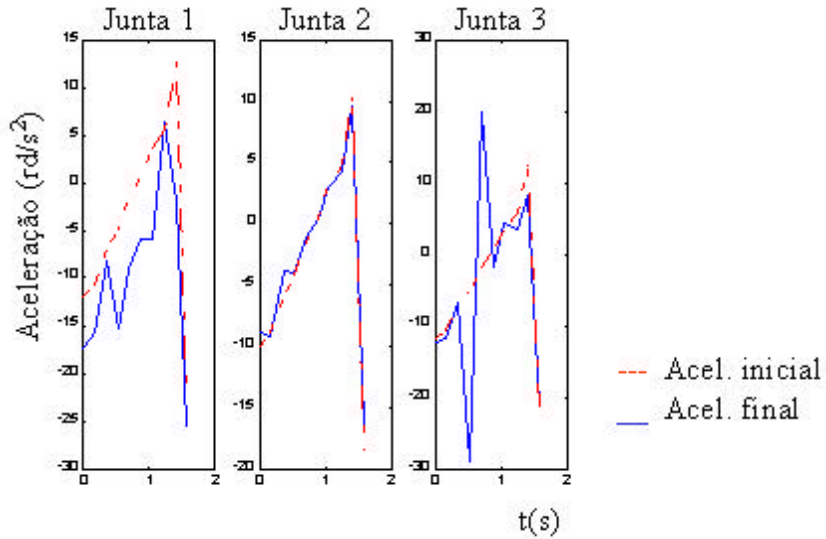


Figura 4 – Resultados para a trajetória ótima da Fig. 2b) em termos da aceleração (coordenadas de junta) ao longo do tempo.

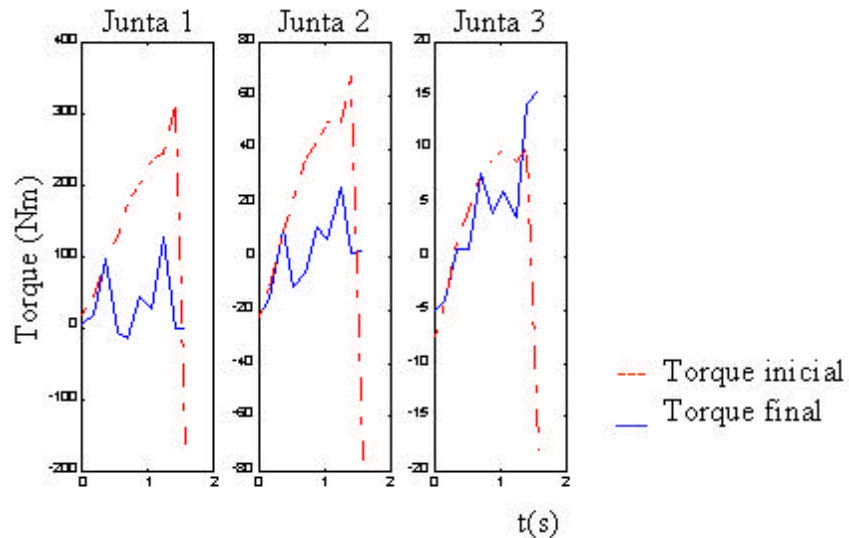


Figura 5 – Resultados para a trajetória ótima da Fig. 2b) em termos do torque nas juntas.

5. CONCLUSÕES

O planejamento de trajetórias para robôs manipuladores foi formulado como um problema de controle ótimo. Para obter a otimização do sistema, a função objetivo foi definida como a potência mecânica envolvida para mover o manipulador. Trata-se de um problema de otimização não-linear que considera as restrições cinemáticas e dinâmicas. Também foram incluídas restrições especiais que asseguram a não colisão com os obstáculos.

Uma aplicação numérica demonstrou a eficiência da estratégia de otimização usada. Pode-se considerar que esta pesquisa contribui ao estado da arte, no sentido que a metodologia aplica Algoritmos Genéticos a problemas com restrições de desigualdade e igualdade utilizando funções de penalidade.

Os resultados estimulam a continuidade da pesquisa quando será considerada a presença de obstáculos no volume de trabalho tridimensional.

6. REFERÊNCIAS

- Chen, J.H., Fu, L.C., and Lin, M.H., 2000, 'Petri-Net and GA Based Approach to Modeling, Scheduling, and Performance Evaluation for Wafer Fabrication', Proceedings of 2000 IEEE International Conference on Robotics and Automation (ICRA), cd- Room, pp. 3403-3408, São Francisco, USA.
- Davis, L., 1991, "Handbook of genetic algorithms", Van Nostrand Reinhold, New York.
- Goldberg, D.E., 1989, "Genetic Algorithms in Search, Optimization, and Machine Learning", Addison-Wesley.
- Haupt, R.L., and Haupt, S.E., 1998, "Practical genetic algorithms", Wiley, New York.
- Houck, C.R., Joines, J.A., Kay, M.G., 1995, "A Genetic Algorithm for Function Optimization: A Matlab Implementaion", NCSU-IE Technical Report 95-09.
- Lee, J.H., Eom, K.S., Yi, B-J., and Suh, I.H., 2001, 'Design of a New 6-DOF Parallel Haptic Device', Proceedings of 2001 IEEE International Conference on Robotics and Automation (ICRA), cd- Room, pp. 886-891, Seoul, Korea.
- Kirkpatrick, S., Gelatt, C.D., Vecchi, M.P., 1983, "Optimization by Simulated Annealing", Science, Vol. 220, No. 4598, pp. 671-680.
- Michalewicz, Z., 1996, "Genetic Algorithms + Data Structures = Evolution Programs", Springer-Verlag AI Series, New York.
- Mitchell, M., 1994, "An introduction to genetic algorithms", MIT Press, New York.
- Saramago, S.F.P. and Steffen Jr., V., 1999, "Dynamic Optimization for the Trajectory Planning of Robot Manipulators in the Presence of Obstacles", Journal of the Brazilian Society of Mechanical Sciences, Vol. XXI, No. 3, pp. 371-383.
- Saramago, S.F.P. and Steffen Jr., V., 2001, "Trajectory modeling of robots manipulators in the presence of obstacles", Journal of Optimization Theory And Applications, Vol.110, n.1, p.17-34.
- Saramago, S.F.P., Assis, E.G., and Steffen Jr., V., 1999, "Simulated annealing: some applications in mechanical systems optimization", Proceedings of the XX Iberian Latin-American Congress on Computational Methods in Engineering (CILAMCE), cd- Room, São Paulo, Brazil.
- Steffen Jr., V., Rade, D.A. and Inman, D.J., 2000, "Using Passive Techniques for Vibration Damping in Mechanical Systems", Journal of the Brazilian Society of Mechanical Sciences, Vol. XXII, No. 3, pp. 411-421.
- Thanapandi, C.M., Walairacht, A., Ohara, S., 2001, "Multi-Component Genetic Algorithm For Generating Best Bending Sequence And Tool Selection In Sheet Metal Parts", Proceedings of 2001 IEEE International Conference on Robotics and Automation (ICRA), cd- Room, pp. 830-835, Seoul, Korea.
- Vanderplaats, G., 1984, "Numerical Optimization Techniques for Engineering Design", McGraw-Hill Inc., USA, 332 p.
- Zhang, Y., and Ji, Q., 2001, "Camera Calibration With Genetic Algorithms", Proceedings of 2001 IEEE International Conference on Robotics and Automation (ICRA), cd- Room, pp. 2179-2184, Seoul, Korea.

GENETIC ALGORITHM APPLIED TO OPTIMUM PATH PLANNING OF ROBOT MANIPULATORS

Sezimária F. P. Saramago

College of Mathematics - Federal University of Uberlândia

Campus Santa Mônica- CEP 38400-902 Uberlândia, MG, Brazil

e-mail: saramago @ ufu.br

***Abstract.** Genetic algorithm is a subset of evolutionary algorithms that model biological processes to optimize highly complex cost functions. This algorithm allows a population composed of many individuals to evolve under specified selection rules to a state that maximizes the “fitness”, that is to say, minimizes the cost function. Robots imitate biological movement, and genetic algorithm imitates biological survival. The two topics seem to be a perfect match, and many researches have made that connection. A robot trajectory describes the position, the orientation, the velocity, and the acceleration of each robot components as a function of time. When repetitive processes are imposed, it is possible to develop a methodology to move a robot manipulator along a specified geometric path avoiding obstacles. This can be achieved with minimum cost through optimization techniques. Penalty functions have been used to avoid constraint violations during the minimization process. The nature of the obstacle constraints is such that, in general, several local minima exist and can be observed throughout the numerical procedure. Genetic algorithm is a random technique capable of jump out of a local minimum, particularly in the case where traditional techniques fail. In this paper, the path planning of a planar robot with three-link arm has been calculated, taking in account the presence of the obstacles in the robot workspace. Basic computational characteristics are outlined and numerical examples have been reported to discuss the results and efficiency of the proposed methodology.*

***Keywords.** Optimization, Genetic Algorithm, Robot manipulators, Trajectory Planning.*