

## **ALAPTROM: AMBIENTE LABVIEW E AUTOCAD PARA PLANEJAMENTO DA TRAJETÓRIA DE ROBÔS MÓVEIS**

**Ricardo Artigas Langer** – ricardo\_langer@hotmail.com

Pontifícia Universidade Católica do Paraná, Grupo Produtrônica  
Graduação em Engenharia Mecatrônica (Controle e Automação)  
Rua Imaculada Conceição, 1155, CEP 80215-901 – Curitiba - Paraná

**Tiago Francesconi** – tiagofrancesconi@hotmail.com

Pontifícia Universidade Católica do Paraná, Grupo Produtrônica  
Graduação em Engenharia Mecatrônica (Controle e Automação)  
Rua Imaculada Conceição, 1155, CEP 80215-901 – Curitiba - Paraná

**Leandro dos Santos Coelho** – leandro.coelho@pucpr.br

Pontifícia Universidade Católica do Paraná, Grupo Produtrônica  
Programa de Pós-Graduação em Engenharia de Produção e Sistemas  
Laboratório de Automação e Sistemas, Rua Imaculada Conceição, 1155  
CEP 80215-901 – Curitiba - Paraná

***Resumo:** Os algoritmos genéticos são metodologias de busca estocástica e otimização de parâmetros que seguem os exemplos do comportamento natural das espécies vivas baseados nas teorias da evolução natural de Darwin e genética de Mendel. Este artigo apresenta uma ferramenta computacional baseada em algoritmos genéticos denominada de ALAPTROM para o projeto e otimização do planejamento de trajetórias de um robô móvel em um ambiente estático e conhecido com obstáculos. A ferramenta de software ALAPTROM foi desenvolvida para gerar um modelo do ambiente através do software AutoCAD e o algoritmo de otimização é implementado em software LabVIEW. Neste artigo, exemplos de simulação são descritos com foco especial em como o LabVIEW é utilizado para implementar a otimização baseada em algoritmos genéticos para planejamento de trajetória de um robô móvel, visando propósitos educacionais.*

***Palavras-chave:** LabVIEW, AutoCAD, otimização, algoritmo genético, robótica móvel.*

### **1. INTRODUÇÃO**

Os métodos de otimização e busca estocástica inspirados nos princípios da evolução biológica natural têm recebido crescente interesse nas últimas décadas, devido principalmente a sua versatilidade para a resolução de problemas complexos, nas áreas de otimização e aprendizado de máquina. O desenvolvimento de modelos computacionais, inspirados nos mecanismos evolucionários (ou evolutivos), caracteriza-se pela configuração de algoritmos de otimização robustos e sistemas adaptativos.

Os algoritmos genéticos são uma família de modelos computacionais inspirados na evolução natural de Darwin e genética de Mendel (GOLDBERG, 1989, 1994). Outros algoritmos evolucionários (ou evolutivos) incluem estratégias evolucionárias, programação genética, programação evolutiva, evolução diferencial e sistemas classificadores (BÄCK *et al.*, 1997).

Os algoritmos genéticos são utilizados em problemas na otimização em telecomunicações, escalonamento, robótica móvel, manufatura, reconhecimento de faces, identificação, previsão, controle, sistemas de potência, configuração de *hardware*, processamento de imagens, otimização de forma e processamento de sinais. Recentemente a robótica tem usado tais algoritmos no planejamento de trajetórias de robôs móveis em caminhos com obstáculos (XIAO *et al.*, 1997; TU & YANG, 2003), em aplicações na agricultura (FERENTINOS *et al.*, 2002) e em cooperação de robôs (CAI & PENG, 2002).

Em paralelo a crescente utilização de algoritmos genéticos observa-se também o aumento exponencial da utilização do *software* LabVIEW™, da National Instruments, no desenvolvimento de soluções, no meio acadêmico e industrial, em instrumentação de testes e ensaios e controle da produção nestes últimos dez anos (ERTUGRUL, 2000; SCHWARTZ & DUNKIN, 2000). O LabVIEW™ é uma linguagem de programação gráfica com interface amigável que utiliza ícones, ferramentas e objetos em vez de linhas de texto para criar aplicações. Outro *software* com disseminada utilização tanto acadêmica quanto industrial é o AutoCAD. O AutoCAD possui funcionalidade e especificações que permitem o desenvolvimento de aplicações que necessitem modelagem de sólidos, banco de dados de imagens e visualização gráfica. O AutoCAD é útil para de geração de modelos gráficos do ambiente de movimentação de um robô móvel em ambiente industrial (SMITH *et al.*, 1999).

Neste artigo é apresentada a concepção de um sistema denominado de ALAPTROM que determina e otimiza a trajetória de um robô móvel utilizando otimização por algoritmos genéticos, este implementado em LabVIEW™, usando dados recebidos de um sistema CAD (*Computer-Aided Design*). Integrando assim, abordagens emergentes na concepção de um projeto de *software* (LabVIEW™ e AutoCAD) com uma técnica de otimização (algoritmos genéticos) para robótica móvel.

O artigo é organizado da seguinte forma. Na seção 2 é descrita a metodologia de otimização do planejamento de trajetórias para robôs móveis usando algoritmos genéticos. Um estudo de caso é descrito na seção 3. Na seção 4, a implementação em LabVIEW™ do ambiente de planejamento de trajetórias para robôs móveis é comentada em detalhes. Na seção 5, a conclusão e as perspectivas de futuros trabalhos são discutidos.

## **2. OTIMIZAÇÃO DE TRAJETÓRIA BASEADA EM ALGORITMOS GENÉTICOS**

O planejamento de trajetórias é uma das importantes tarefas em sistemas de robótica, principalmente para aplicações com robôs móveis inteligentes e/ou autônomos. Existem dois tipos fundamentais de planejamento de trajetórias: (i) planejamento de trajetória adaptativo dinâmico, que permite um robô móvel responder a situações inesperadas enquanto engajado no procedimento de resolução do problema, isto é, ele é capaz de produzir um novo caminho em resposta a mudanças ambientais, e (ii) planejamento de trajetória estática, que permite ao robô móvel mover-se em um ambiente conhecido *a priori* (Tu & Jang, 2003).

Em ambientes estáticos, o espaço de trabalho (mapa do ambiente) é conhecido e a trajetória pode ser gerada *a priori*. Neste caso, o planejamento de trajetórias é restrito ou irrestrito dependendo das restrições impostas a movimentação dos robôs, tais como a presença de obstáculos (Tu & Jang, 2003).

A literatura é rica em abordagens para resolução de problemas de planejamento de trajetórias de robôs móveis na presença de obstáculos estáticos e obstáculos móveis. Uma dos mais populares métodos de planejamento é o de campos potenciais artificiais (Tsuji *et al.*, 2002). Entretanto, este método dá somente uma solução de trajetória que pode não ser a menor em um ambiente estático. As principais dificuldades na determinação de uma trajetória ótima é devido ao fato que os métodos analíticos são muito complexos de serem utilizados em tempo real e os métodos de busca enumerativos são muito afetados pelo tamanho do espaço de busca.

Recentemente, tem sido difundido o interesse na utilização de algoritmos evolucionários (AEs), geralmente algoritmos genéticos para o planejamento de trajetórias para robôs móveis quando o espaço de busca é grande ou mesmo complexo. A seguir são apresentados os fundamentos dos algoritmos genéticos para otimização e robótica móvel

## 2.1 FUNDAMENTOS DOS ALGORITMOS GENÉTICOS

Os algoritmos evolucionários são paradigmas computacionais da inteligência computacional para resolução de problemas, inspirados nos princípios da teoria evolutiva de Darwin e na genética de Mendel. Uma variedade de algoritmos evolucionários tem sido desenvolvida e apresentada na literatura. Entretanto, todos os algoritmos evolucionários dividem uma base conceitual comum, através de procedimentos de seleção, cruzamento e mutação. Os algoritmos evolucionários são especialmente úteis às tarefas de otimização global, onde os métodos determinísticos podem levar a soluções de mínimos locais.

Os algoritmos genéticos são técnicas robustas e eficientes em espaços de procura irregulares, multidimensionais e complexos, e caracterizam-se por (GOLDBERG, 1989): (i) operam em uma população de pontos; (ii) não requerem derivadas; (iii) trabalham com a codificação de seu conjunto de parâmetros; (iv) realizam transições probabilísticas, em vez de regras determinísticas; (v) necessitam apenas de informação sobre o valor de uma função objetivo para cada indivíduo da população.

Para aplicar os algoritmos genéticos, uma função de aptidão (*fitness*) deve ser definida para avaliação de quão adequada é a identificação do processo. Através dos operadores de seleção, cruzamento e mutação, os indivíduos (soluções factíveis do problema) com maior aptidão são encontrados. Um operador de seleção elitista garante que os indivíduos com maior aptidão se propagarão para as futuras gerações. O ciclo básico dos dados num algoritmo genético é baseado no pseudocódigo da figura 1.

```
geração  $f \leftarrow 0$ 
geração da população inicial ( $P(f)$ )
avaliação da aptidão da população ( $P(f)$ )
enquanto o critério de parada não é atingido
{
   $f \leftarrow f + 1$ 
   $P(f) = \text{seleção}(P(f-1))$ 
  cruzamento ( $P(f)$ )
  mutação ( $P(f)$ )
  avaliação da aptidão da população ( $P(f)$ )
}
```

Figura 1. Pseudocódigo básico num algoritmo genético.

Os operadores utilizados no algoritmo genético abordado foram os operadores clássicos de seleção, cruzamento e mutação.

A operação de seleção escolhida foi uma estratégia elitista (AHN & RAMAKRISHNA, 2003). Para atender a ambos os objetivos de diversidade da população e sustentar a capacidade de convergência do algoritmo foram usados conceitos de programação evolutiva (YAO *et al.*, 1999).

O operador de cruzamento combina dois indivíduos para formarem novos indivíduos (filhos) que tenham alta probabilidade de apresentarem melhor aptidão que seus pais.

A operação de mutação visa uma alteração aleatória de um indivíduo da população, visando inserir novas informações genéticas na população e prevenindo a convergência

prematura para um mínimo local. O operador de mutação permite que novas áreas da superfície de resposta sejam exploradas. Os algoritmos genéticos oferecem um melhoramento da aptidão dos indivíduos que após a realização de muitas gerações (ciclo evolucionário) e visa criar indivíduos contendo um conjunto de variáveis otimizadas adequadamente (ver diagrama apresentado na figura 2).

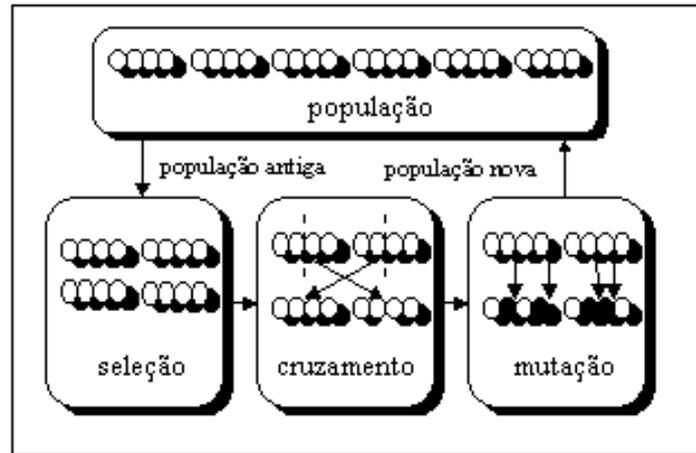


Figura 2. Ciclo básico dos dados nos algoritmos genéticos canônicos.

## 2.2 IMPLEMENTAÇÃO DO ALGORITMO GENÉTICO

O ambiente de programação escolhida para executar o algoritmo genético mencionado foi o LabVIEW™. Esta é uma poderosa ferramenta voltada á instrumentação e prototipagem, com uma interface amigável e robusta, diminuindo de forma acentuada o tempo gasto em desenvolvimento e depuração do código. Dessa forma, era apropriado utilizar um ambiente de programação com tais qualidades na codificação do sistema ALAPTROM.

O sistema implementado em LabVIEW™ é alimentado por um arquivo composto por informações dimensionais gerado por um sistema de CAD, neste caso foi utilizado o *software* AutoCAD 2000, devido a sua popularização industrial e facilidade de customização. Através de rotinas construídas nas linguagens Autolisp e DCL mapear toda uma área de trabalho e seus respectivos obstáculos é possível.

## 3. ESTUDO DE CASO: GERAÇÃO DE TRAJETÓRIA PARA UM AMBIENTE COM A PRESENÇA DE OBSTÁCULOS

Para melhor explicar os resultados optou-se por apresentar uma análise de um cenário fictício construído em CAD. Partindo-se da modelagem em AutoCAD 2000 apresentada na figura 3, um arquivo com as informações dimensionais dos obstáculos e da área de trabalho gerado por uma rotina em LISP. Objetiva-se uma trajetória ótima que parta do ponto inferior esquerdo do mapa e termine no canto superior direito, sem cruzar nenhum obstáculo.

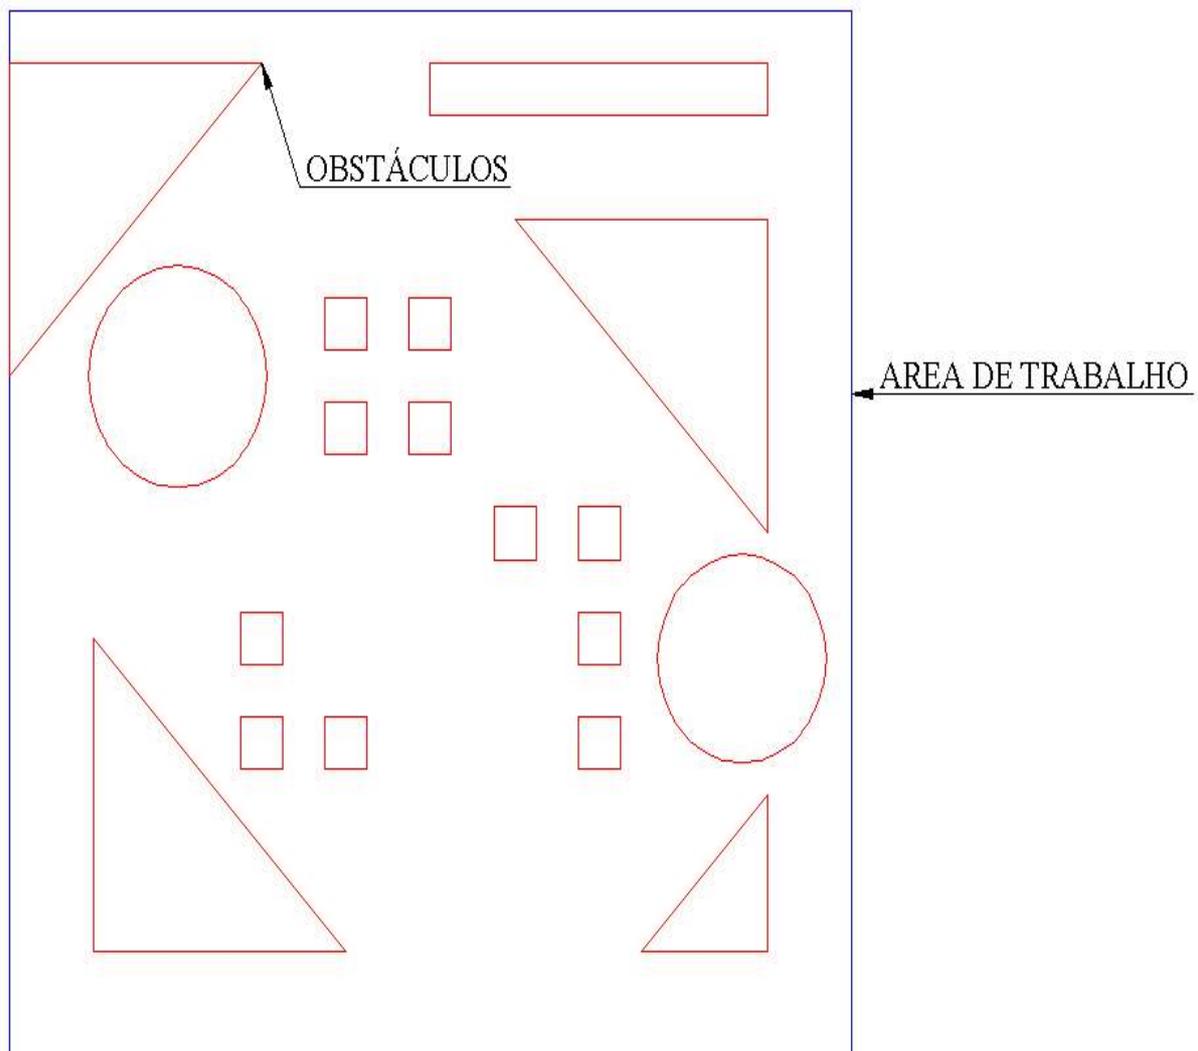


Figura 3. Planta baixa de um ambiente de trabalho modelado em *software* de CAD.

O programa em LabVIEW™ abre o arquivo de informações e reconstrói o mapa através de uma matriz de dados, como se esta fosse uma imagem monocromática, usando esta matriz para calcular a função de *fitness*. Depois de executado o algoritmo genético, a melhor trajetória encontrada é salva em um arquivo que é aberto pelo AutoCAD 2000. Sobrepondo a informação da modelagem dos obstáculos com a trajetória proposta tem-se a figura 4.



Figura 4. Trajetória encontrada pelo algoritmo genético ainda no LABVIEW™.

Os parâmetros de entrada do ALAPTROM foram: probabilidade de cruzamento de 80% e probabilidade de mutação de 1%, e seleção por roleta com elitismo. Foram usados 30 indivíduos na população e 13 bits de precisão para representação das soluções (indivíduos) da população do algoritmo genético (canônico ou binário).

O problema de otimização formulado para ser resolvido pelo algoritmo genético consiste de um problema de otimização discreta, onde a função objetivo  $f(x,y)$ , que é a ligação entre o algoritmo genético e o ambiente de movimentação do robô, visa a minimização da trajetória total a ser percorrida pelo robô móvel e é regida por

$$f(x,y) = \alpha d_{obj} + \lambda n_o \quad (1)$$

$$d_{obj} = \sum_{i=0}^{n_p} \sqrt{(x(i+1) - x(i))^2 + (y(i+1) - y(i))^2} \quad (2)$$

onde  $\alpha$  e  $\lambda$  são fatores de ponderação,  $d_{obj}$  representa a distância euclidiana entre o ponto inicial e o ponto meta e  $n_o$  denota o número de obstáculos atingidos pela movimentação do robô se a trajetória planejada fosse  $d_{obj}$ , e  $n_p$  é o número de pontos de mudança de trajetória do robô (parâmetro de projeto do usuário, neste artigo). Nota-se pela equação (1) que existe um termo  $\lambda$  ponderação (penalização) de soluções indesejáveis, ou seja, as trajetórias que interceptam obstáculos (SIERAKOWSKI *et al.*, 2004). Neste caso, a função *fitness* a ser avaliada pelo algoritmo genético visa a maximização de

$$fitness = \frac{K_c}{f(x,y) + \epsilon} \quad (3)$$

onde  $K_c$  e  $\epsilon$  são constantes de escala (adotadas neste artigo como iguais a 1). Na figura 5 pode-se acompanhar a convergência do algoritmo genético. Nesta figura são apresentados o melhor *fitness* e a média dos *fitness* da população em função do número de gerações.

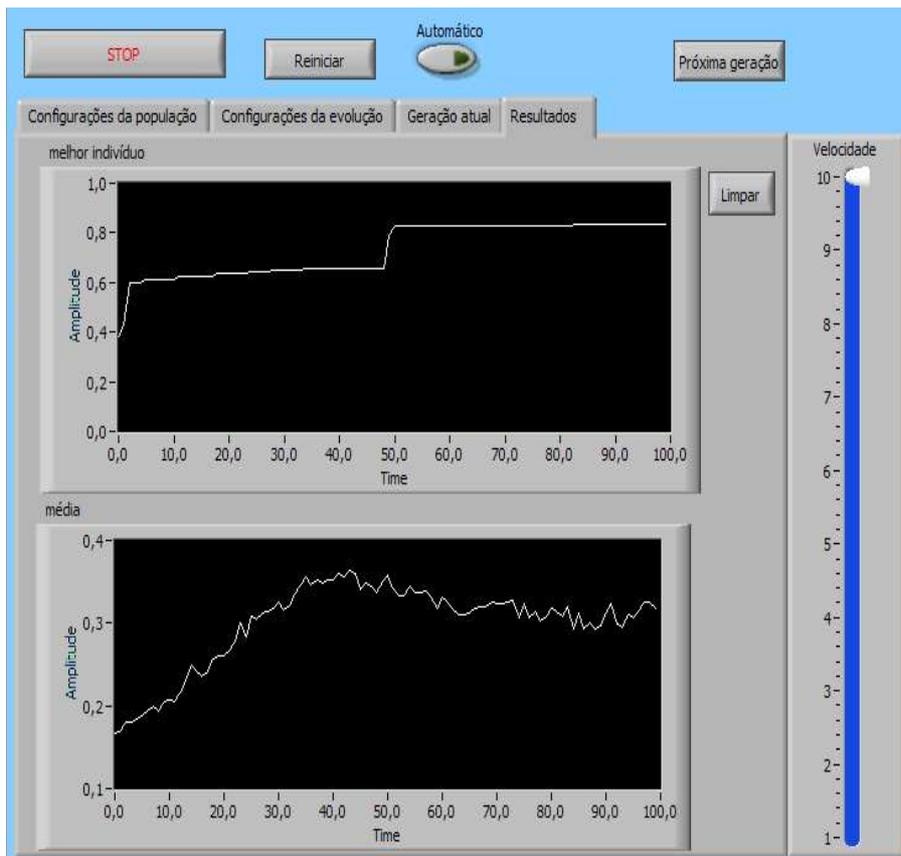


Figura 5. Gráficos da evolução do *fitness* do melhor indivíduo e da média da população em função do número de gerações.

Uma outra possibilidade permitida pelo programa é adicionar a técnica de torneios no algoritmo genético como apresentada por YAO *et al.* (1999). Na figura pode-se observar a comparação entre as evoluções com e sem o método de torneio para seleção no algoritmo genético. Os gráficos da figura 6, amarelo e azul utilizaram o torneio e as demais não. Fica desta forma evidente que o método aumenta em muito a velocidade de convergência do algoritmo, mas para que estes resultados fossem conseguidos a probabilidade de mutação foi aumentada para 10%, para garantir a diversidade da população.

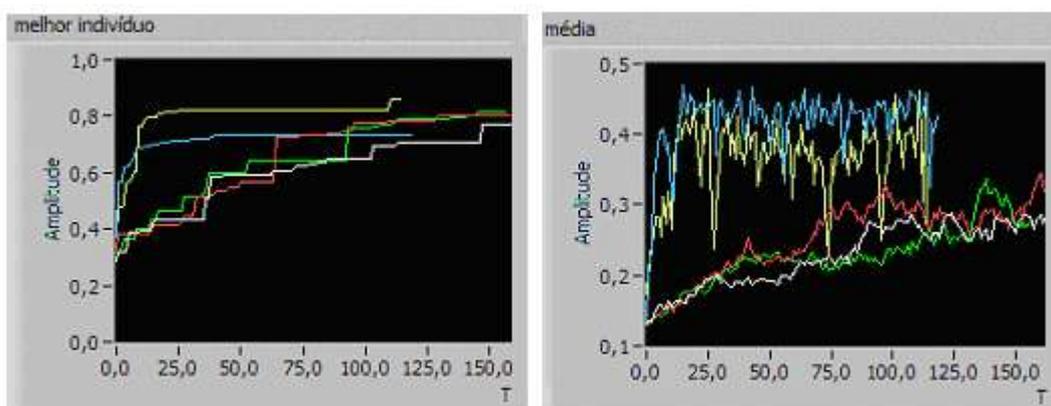


Figura 6. Gráficos da evolução do *fitness* do melhor indivíduo e da média da população em função do número de gerações para várias evoluções.

A trajetória encontrada pelo algoritmo genético e apresentada na figura 4 foi recuperada pelo AutoCAD 2000 e sobreposta à planta baixa da figura 3. O resultado está na figura 7.

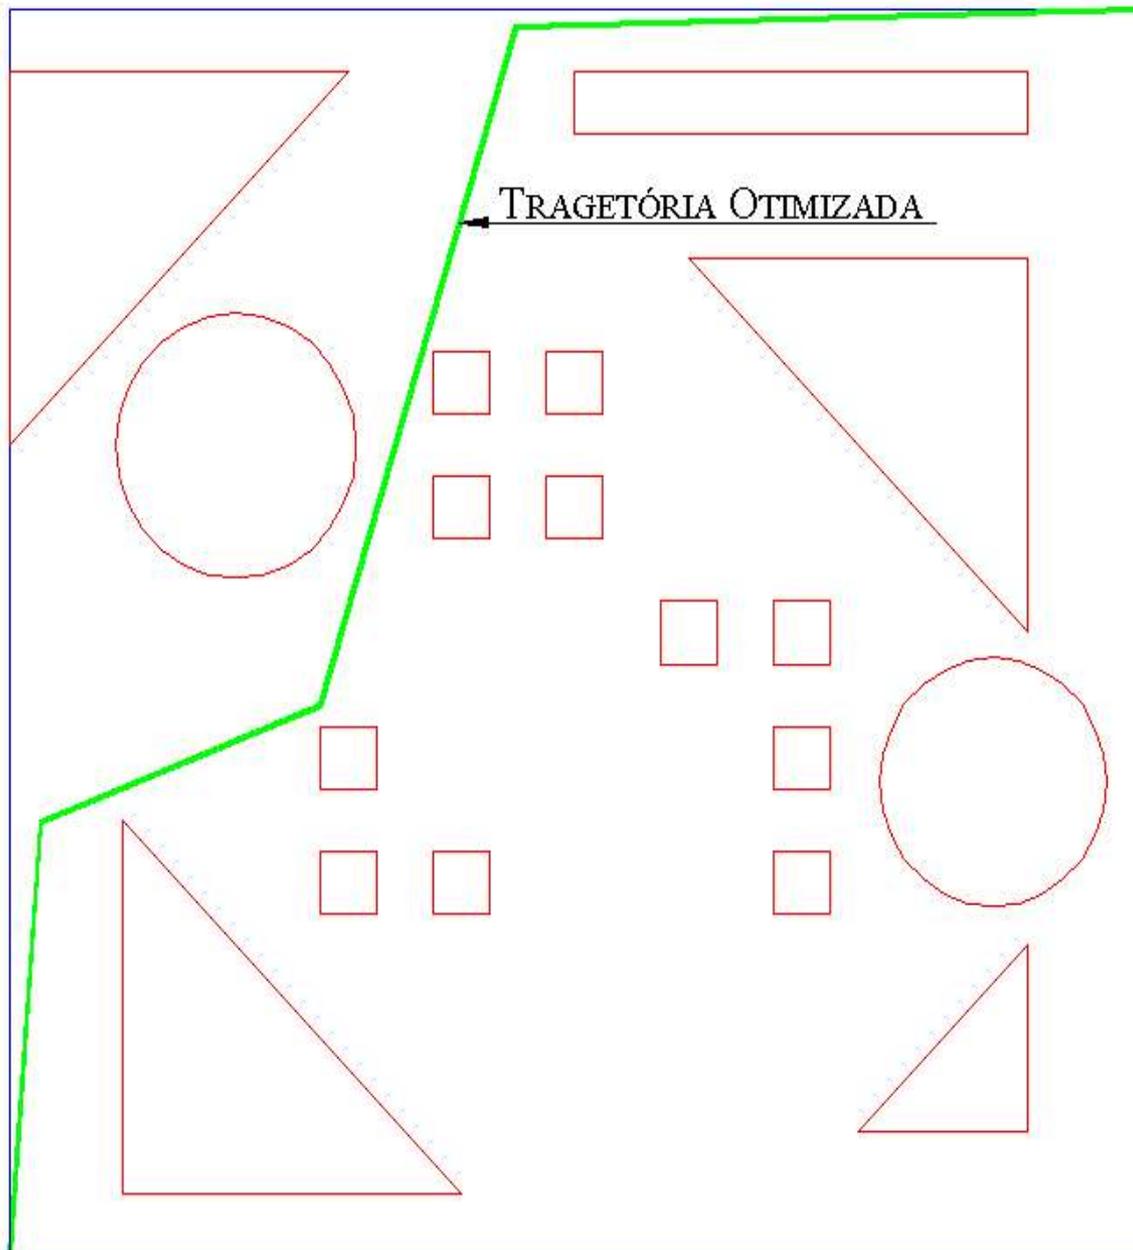


Figura 7. Planta baixa modelada em AutoCAD com uma trajetória sobreposta.

#### 4. COMENTÁRIOS SOBRE O CÓDIGO IMPLEMENTADO EM LabVIEW™

O algoritmo foi implementado de forma a ser de fácil entendimento, assemelhando-se ao máximo com um fluxograma que representasse intrinsecamente o algoritmo genético. Os blocos de decisão referem-se à execução condicional das opções disponíveis do programa. Representam, da esquerda para a direita, a elitização, o torneio, o cruzamento e a mutação. O bloco de decisão maior que reúne as demais é relacionado a geração da população e a sub-rotina mais a direita calcula o *fitness* de todos os indivíduos da população do algoritmo genético. Esta última contém os dados referentes à planta baixa armazenados localmente.

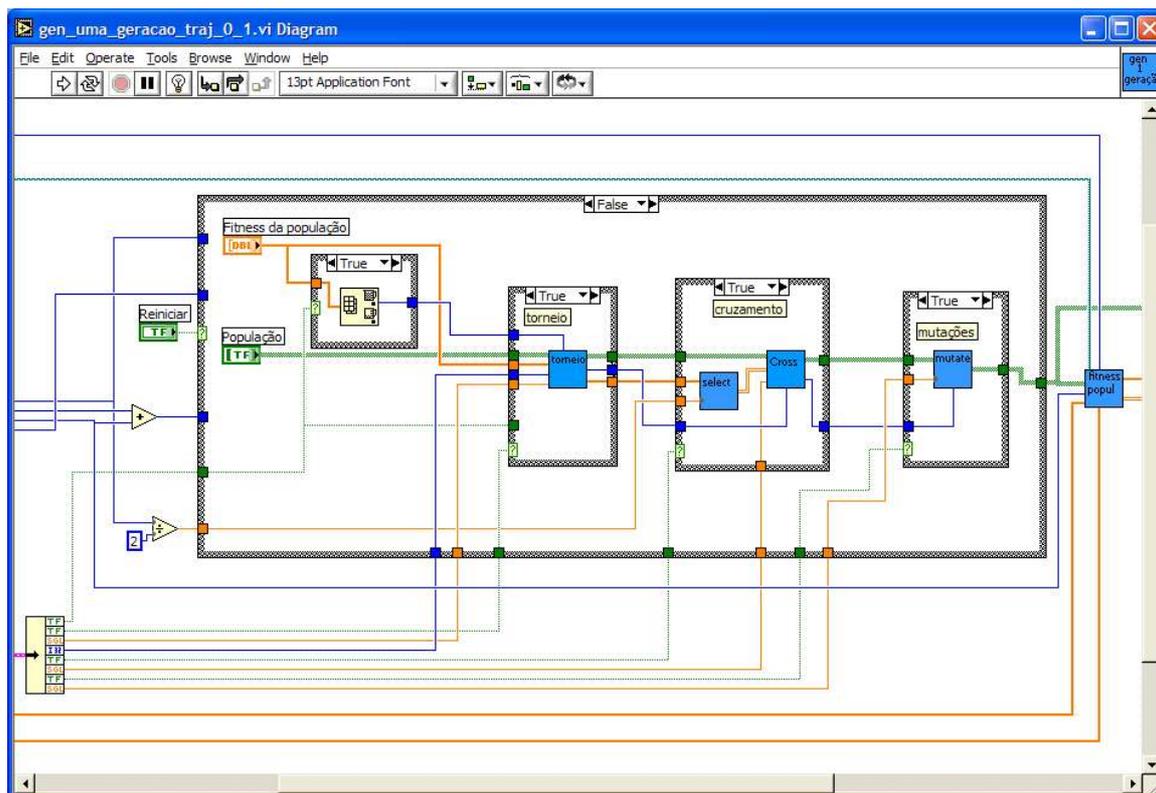


Figura 8. Diagrama do código em LabVIEW que executa uma geração do algoritmo genético.

A rotina apresentada na figura 8 é repetida dentro de um laço até que seja atingido o número máximo de gerações. O usuário pode interromper a evolução a qualquer momento, rodá-la passo-a-passo e visualizar qualquer um dos indivíduos em um mapa como está apresentado na figura 4. Evoluções subseqüentes podem ter os seus resultados acumulados em um mesmo gráfico, conforme apresentado na figura 6, para fins de comparação.

## 5. CONCLUSÃO E PERSPECTIVAS DE FUTUROS TRABALHOS

O problema de planejamento de trajetória de robôs móveis em ambientes com obstáculos tem recebido muita atenção nas últimas décadas. O problema básico focado neste artigo é que existe um robô e um ambiente conhecido e estático, e a tarefa do algoritmo de otimização é calcular uma trajetória livre de obstáculos que descreve a movimentação do robô da posição atual até alguma posição que seja sua meta. As variações e extensões para este problema básico são numerosas.

Neste artigo foi descrito um sistema denominado de ALAPTROM para o projeto e otimização da trajetória de um robô móvel utilizando otimização através de algoritmos genéticos, este implementado em LabVIEW™, usando dados recebidos de um sistema CAD (*Computer-Aided Design*). O projeto da interface do ALAPTROM visou uma abordagem amigável para usuário e pode ser estendida para sistemas de otimização mais complexos.

## REFERÊNCIAS BIBLIOGRÁFICAS

AHN, C. W.; RAMAKRISHNA, R. S. **Elitism-based compact genetic algorithms**. IEEE Transactions on Evolutionary Computation, v. 7, n. 4, p. 367-385, 2003.

- BÄCK, T.; HAMMEL, U.; SCHWEFEL, H. –P. **Evolutionary computation: comments on the history and current state**. IEEE Transactions on Evolutionary Computation, v. 1, n. 1, p. 3-17, 1997.
- CAI, Z.; PENG, Z. **Cooperative coevolutionary adaptive genetic algorithm in path planning of cooperative multi-mobile robot systems**. Journal of Intelligent and Robotic Systems, v. 33, p. 61-71, 2002.
- CAO, Y. J.; WU, Q. H. **Mechanical design optimization**. IEEE Conference on Evolutionary Computation, Indianapolis, USA, p. 443-446, 1997.
- ERTUGRUL, N. **Towards virtual laboratories: a survey of LabVIEW-based teaching learning tools and future trends**. International Journal of Engineering Education, v. 16, n. 3, 2000.
- FERENTINOS, K. P.; ARVANITIS, K. G.; SIGRIMIS, N. **Heuristic optimization methods for motion planning of autonomous agricultural vehicles**. Journal of Global Optimization, v. 23, p. 155-170, 2002.
- GOLDBERG, D. E. **Genetic and evolutionary algorithms come of age**. Communications of the ACM, v. 37, n. 3, p. 113-119, 1994.
- GOLDBERG, D. **Genetic algorithms in search optimization and machine learning**, Reading: MA: Addison-Wesley, 1989.
- SCHWARTZ, T. L.; DUNKIN, B. M. **Facilitating interdisciplinary hands-on learning using LabView**, International Journal of Engineering Education, v. 16, n. 3, 2000.
- SIERAKOWSKY, C. A.; COSTA, A. C. P. L.; COELHO, L. S. **Uma comparação de algoritmos genéticos, programação evolucionária e evolução diferencial para otimização de trajetórias de robôs móveis**. II Encontro de Robótica Inteligente, Congresso da SBC, Salvador, BA, 2004.
- SMITH, P. J.; SMITH, J. S.; LUCAS, J. **Localization of a UUV within structures using range data and world modelling techniques**. International Journal of Systems Science, v. 30, n. 9, p. 915-928, 1999.
- TSUJI, T.; TANAKA, Y.; MORASSO, P. G.; SANGUINETI, V.; KANEKO, M. **Bio-mimetic trajectory generation of robots via artificial potential field with time base generator**. IEEE Transactions on Systems, Man and Cybernetics, Part C, v. 32, n. 4, p. 426-439, 2002.
- TU, J.; YANG, S. X. **Genetic algorithm based path planning for a mobile robot**. Proceedings of the IEEE International Conference on Robotics & Automation, Taipei, Taiwan, p. 1221-1226, 2003.
- XIAO, J.; MICHALEWICZ, Z.; ZHANG, L.; TROJANOWSKI, K. **Adaptive evolutionary planner/navigator for robots**. IEEE Transactions on Evolutionary Computation, v. 1, n. 1, p. 18-28, 1997.
- YAO, X.; LIU, Y.; LIN, G. **Evolutionary programming made faster**. IEEE Transactions on Evolutionary Computation, v. 3, n. 2, p. 82-102, 1999.

## **ALAPTROM: AMBIENTE LABVIEW E AUTOCAD PARA PLANEJAMENTO DA TRAJETÓRIA DE ROBÔS MÓVEIS**

***Abstract:** Genetic algorithms are parameter optimization and stochastic search methodologies following the examples of the natural behavior of living species based on theories of Darwin's natural evolution and Mendel genetics. This paper presents a genetic algorithms-based software tool called ALAPTROM for design and optimization of path planning of a mobile robot in a static and known environment with obstacles. The ALAPTROM software tool was developed to generate a world model by AutoCAD software and the optimization algorithm is implemented with the LabVIEW software. In this paper, simulation examples are described with special focus on how LabVIEW is used to implement*

*the optimization strategy based on genetic algorithms for path planning of a mobile robot for educational proposes.*

***Key-words:*** *LabVIEW, AutoCAD, optimization, genetic algorithm, mobile robot.*