



OTIMIZAÇÃO DE MAPEAMENTO DE ROTAS PARA DRONES PULVERIZADORES

Florisvaldo Cardozo Bomfim Jr¹, Rodrigo dos Santos Soares¹, Rafael Henrique Borges²
Lucas Rodrigues da Silva², Fernando José Portella², Wagner Cardoso³

¹Universidade de Uberaba, Engenharia Elétrica

²Universidade de Uberaba, Sistemas de Informação

³Universidade de Uberaba, Engenharia de Produção

florisvaldo.bomfim@uniube.br

Resumo

RESUMO - O trabalho desenvolvido vem a apresentar um método não convencional de otimização de rotas para drones de pulverização, por meio dos algoritmos genéticos, que consegue encontrar soluções ótimas por uma metodologia que é análoga ao processo de evolução humana.

Palavras-chave: Inteligência Artificial, Drones, Algoritmos Genéticos.

1 INTRODUÇÃO

O mercado atual, vem exigindo a cada dia a otimização de processos e produtos, com isso reduzindo o valor do produto produzindo tornando a empresa mais competitiva no mercado. O trabalho vem a apresentar um método não convencional de rotas que tem por objetivo reduzir os custos com agrotóxicos e otimizar o tempo de cada área de aplicação, com isso reduzindo o desgaste do drone, tanto da parte mecânica quanto da recarga de baterias. A proposta do trabalho foi a de desenvolver um inteligência artificial por meio dos algoritmos genéticos, que tem por objetivo determinar o menor percurso para um drone percorrer toda uma área delimitada, no menor tempo possível.

2 MATERIAIS E MÉTODOS

Nesta seção são discutidos conceitos importantes para o entendimento da proposta apresentada

neste trabalho.

Drones são veículos aéreos não tripulados (VANT), controlados de forma remota. No Brasil, as regras de utilização são regulamentadas pela ANAC¹. Possuem diversas finalidades, desde um simples hobby, quanto para aplicações mais específicas como monitoramento policial ou militar, entrega de produtos, vídeos e fotos de eventos como casamento, formaturas. Amplamente utilizados na agricultura por permitir um melhor monitoramento das plantações, identificando possíveis problemas, doenças e falhas de plantio, possibilitando uma ação rápida e antecipada, evitando perdas na produção. No processo de pulverização de defensivos, permitindo que seja feita de forma precisa e rápida. Drones voltados para agricultura possuem tecnologias diferenciadas como sistema de radar esférico, Resistência à água e poeira, Câmeras duplas para monitoramento, RTK: Posicionamento Cinemático em Tempo-Real alguns possuem plataforma em nuvem para agricultura inteligente.

2.1 ALGORITMOS GENÉTICOS

São algoritmos de otimização numérica, inspirados tanto na seleção natural quanto na genética natural, podendo ser aplicado a uma gama de problemas, sendo usados para ajudar a resolver problemas práticos do dia a dia.

A ideia de usar uma população de soluções para resolver problemas de otimização de engenharia

¹Agência Nacional de Aviação Civil



prática foi considerada, várias vezes, durante as décadas de 1950 e 1960. No entanto, o AG foi inventado por John Holland, em 1960. Os seus motivos para desenvolver tais os algoritmos foram muito além do tipo de resolução de problemas convencionais.(COLEY, David A.,1999)

Constituição dos algoritmos genéticos:

1. Um número ou população de suposições da solução para o problema;
2. Uma maneira de calcular o quão são bons ou ruins as soluções individuais dentro da população;
3. Um método para misturar fragmentos para formar melhores soluções;
4. Um operador de mutação para evitar a perda permanente de diversidade dentro das soluções.

2.1.1 Funcionamento

Em vez de partir de um único ponto (ou adivinhar) dentro do espaço de busca, AG's são inicializados com população de suposições. Estes são geralmente aleatórios e espalhados por todo o espaço de busca. Um algoritmo típico usa três operadores - seleção, recombinação e mutação (escolhidos em parte por analogia com o mundo natural) - a fim de direcionar a população, ao longo de uma série de etapas de tempo ou gerações, para a convergência no ótimo global. Normalmente, essas suposições iniciais são mantidas como codificações binárias (ou strings) das variáveis verdadeiras, embora um número crescente de AG's use "valores reais"(ou seja, base decimal), ou codificações que foram escolhidas para imitar, de alguma maneira, a estrutura de dados naturais do problema.(COLEY, David A.,1999)

Quanto aos três principais operadores da população:

1. A seleção tenta pressionar a população de uma maneira semelhante ao da seleção natural encontrada nos sistemas biológicos.
2. Recombinação permite que as soluções troquem informações de forma semelhante à que é usada por um organismo natural submetido à reprodução sexual.

3. Mutação é usada para mudar aleatoriamente (*flip*) o valor de bits individuais dentro de strings individuais. O uso típico é usado com muita moderação.

Após, os operadores de seleção, recombinação e mutação foram aplicadas à população inicial. Uma nova população será formada e adicionado mais 1 no contador da geração. Este processo de seleção, *crossover* e mutação é continuado até certo número de gerações terem decorrido ou alguma forma de o critério de convergência ser cumprido.

2.1.2 Mutação

No mundo natural, vários processos podem causar mutação. As taxas de bactérias são aproximadamente 2.10^{-3} por genoma por geração (FU90, BA96, p19.). Por meio de uma representação binária, a mutação é particularmente fácil de implementar. A cada nova geração toda a população é varrida, com cada posição de bit em cada corda visitada, e muito ocasionalmente, 1 é invertido para 0 ou vice-versa. A probabilidade de mutação P é tipicamente da ordem de 0,001, ou seja, um bit em cada mil será mutado. No entanto, assim como em todo o resto sobre o AG's, a correta configuração para P dependerá do problema. Alguns autores realizam a mutação, visitando cada posição de bit, jogando aleatoriamente 0 ou 1 e substituindo o bit existente por esse novo valor. Como há uma probabilidade de 50% de o bit pré-existente e o substituto serem idênticos, a mutação será realizada apenas à metade da taxa.

2.1.3 Seleção

A seleção é particularmente simples: os melhores 50% são selecionados para se reproduzir, e o resto é jogado fora. Este é um método prático, mas não é o mais comum. Um dos motivos para isso é que, embora permita o melhor reproduzir (e para o pior); não faz distinção entre "bom" e "muito bom". Além disso, em vez de apenas permitir soluções pobres para avançar para a próxima geração com uma probabilidade muito menor, simplesmente os aniquila (reduzindo a diversidade genética da população). O mais comum operador de seleção proporcional é a roleta. Com isso abordar a probabilidade



de seleção é proporcional à aptidão de um indivíduo.

Elitismo A seleção proporcional não garante a seleção do indivíduo mais apto. Embora pareça contraproducente, isso pode ser vantajoso para alguns problemas porque ele retarda o algoritmo, permitindo que se explore mais o espaço de pesquisa antes da convergência. Elitismo é a técnica que segura a cada geração, os melhores indivíduos para que tais indivíduos não se percam durante a evolução.

2.1.4 Recombinação

O Algoritmo Genético usa *crossover* de ponto único como a recombinação de operadores. Os pares de indivíduos selecionados são submetidos *crossover* a um valor de probabilidade. Um número aleatório, R, é gerado no intervalo entre 0 e 1, e os indivíduos passam por *crossover* se, e somente, R for menor do que P, senão o par prossegue sem cruzamento. A nova população agora é constituída por N indivíduos (o mesmo número que a população original), criados por seleção e *crossover*. A mutação então opera em toda a população, exceto o membro da elite (se o elitismo está sendo aplicado). Finalizado o processo, a população antiga é substituída pela nova e o contador de época é acrescido de mais 1.

2.1.5 Aptidão

Durante cada iteração, os princípios de seleção e reprodução são aplicados a uma população de candidatos que pode variar, dependendo da complexidade do problema e dos recursos computacionais disponíveis. Através da seleção, se determina quais indivíduos conseguirão se reproduzir, gerando um número determinado de descendentes para a próxima geração, com uma probabilidade determinada pela seu índice de aptidão. Em outras palavras, os indivíduos com maior adaptação relativa têm maiores chances de se reproduzir.

2.2 SBX (Simulated Binary Crossover)

O *crossover* binário simulado (SBX – *Simulated Binary Crossover*) trabalha com dois indivíduos

selecionados P1 e P2 e cria dois novos indivíduos C1 e C2. O operador SBX, e o *crossover* Blend são considerados operados auto adaptativos, pois se adaptam automaticamente durante a execução de um algoritmo genético. O *crossover* SBX utiliza uma distribuição de probabilidade não uniforme bimodal. O indivíduo criado é uma aproximação de centro nos dois indivíduos pais, isto é, tem maior probabilidade de ser gerado em duas regiões, cujos centros são os dois indivíduos pais. (Deb, Joshi e Anand, 2001).

$$u_i = rand(1) \quad (1)$$

$$B_{qi} = (2 \cdot u_i)^{\frac{1}{\eta+1}} \quad u_i \leq \frac{1}{2} \quad (2)$$

$$B_{qi} = \left(\frac{1}{2 \cdot (1 - u_i)} \right)^{\frac{1}{\eta+1}} \quad u_i > \frac{1}{2} \quad (3)$$

$$C_1 = \frac{1}{2} \cdot ((1 - B_{qi}) \cdot P_1 + (1 + B_{qi}) \cdot P_2) \quad (4)$$

$$C_2 = \frac{1}{2} \cdot ((1 - B_{qi}) \cdot P_2 + (1 + B_{qi}) \cdot P_1) \quad (5)$$

onde o índice i é uma referência ao i -ésimo alelo; B_{qi} , é definido pela Equação 2 e 3; u_i , uma variável aleatória com distribuição uniforme entre 0 e 1. Note que, como não pode existir coeficientes negativos, existe um teste que traz para zero os alelos que porventura se tornem negativos ao final da recombinação.

3 RESULTADOS E DISCUSSÃO

Para o desenvolvimento deste trabalho, foi utilizada a ferramenta matemática Scilab®, sendo o ambiente de desenvolvimento do algoritmo genético utilizado para a modelagem das funções de transferência. O AG foi configurado com valores em torno dos considerados padrões pela literatura (2017, Bomfim Junior):

- População : 2000
- Gerações : 200
- Números de indivíduos de torneio : 3^2

²Três indivíduos são selecionados aleatoriamente e logo após é observado aquele que possui a melhor aptidão, sendo o vencedor e enviado para o próximo processo.



- Probabilidade de recombinação: 0.95 ou 95% (na falha, os pais selecionados são copiados para a próxima geração)
- Probabilidade de mutação: 0.05%
- Atualização da geração com troca dos pais, pelos filhos.

Foram lançadas os 22 pontos com valores de longitude e latitude aleatória, onde inicialmente a primeira rota apresentou uma distância de 1076.76 metros conforme apresentado nas figuras 1, 2 e 3, até atingir uma distância mínima de **389,28 metros**.




Figura 1: Indivíduos entre a 2 e 24 geração




Figura 2: Indivíduos entre a 42 e 64 geração

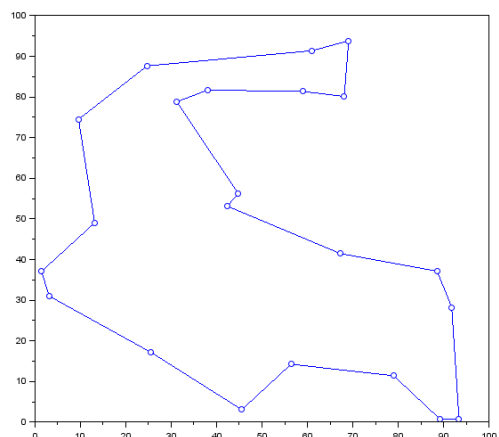


Figura 3: Indivíduos entre a 84 e 100 geração

4 CONCLUSÃO

Por meio dos resultados obtidos, foi comprovado que os algoritmos genéticos, é uma poderosa ferramenta de otimização, pois foi capaz de encontrar uma trajetória ótima, que possui a menor trajetória para realizar a pulverização de agrotóxico com isso reduzindo o custo de manutenção e desgaste dos equipamentos.

Referências

[1] Biradar, S., Hote, Y. V., and Saxena, S. (2016). Reduced-order modeling of linear time invariant systems using big bang big

crunch optimization and time moment matching method. *Applied Mathematical Modelling*, 40(15–16):7225 – 7244.

[2] Cabral, H. A. and de Melo, M. T. (2011). Using genetic algorithms for device modeling. *IEEE Transactions on Magnetics*, 47(5).

[3] Deb, Kalyanmoy; Agrawal, R. B. (1995). Simulated binary crossover for continuous search space. *Complex Systems*, 9:115–148.

[4] Goldberg, D. (1989). *Genetic Algorithms in Search, Optimization and Machine*



- Learning. Addison-Wesley Professional.
- [5] He, T., Hong, L., Kaufman, A., and Pfister, H. (1996). Generation of transfer functions with stochastic search techniques. In Proceedings of the 7th Conference on Visualization '96, VIS '96, pages 227–ff., Los Alamitos, CA, USA. IEEE Computer Society Press.
- [6] Loyka, S. L. (1999). Applying genetic algorithm to modeling nonlinear transfer functions. In Telecommunications in Modern Satellite, Cable and Broadcasting Services, 1999. 4th International Conference on, volume 1, pages 247–250 vol.1.
- [7] Marlin, T. E. (2014). Process Control: designing processes and control systems for dynamic performance. McGraw-Hill, Inc., 2 edition.
- [8] McCall, J. (2005). Genetic algorithms for modelling and optimisation. Journal of Computational and Applied Mathematics, 184:205–222.
- [9] Nedelea, L., Neag, M., Topa, M., Festila, L., and Topa, V. (2006). Analog filter transfer function optimization based on a genetic algorithm. In Applied Electronics, Pielsen.
- [10] Tavakolpour, A. R., Darus, I. Z. M., Tokhi, O., and Mailah, M. (2010). Genetic algorithm-based identification of transfer function parameters for a rectangular flexible plate system Engineering Applications of Artificial Intelligence.
- [11] MAYA, Paulo Alvaro, and Fabrizio LEONARDI. "Controle essencial." Ed Pearson Prentice Hall (2011).
- [12] OGATA, Katsuhiko et al. Engenharia de Controle moderno; tradução Paulo Álvaro Maya; revisão técnica Fabrizio Leonardi.[et al]. São Paulo: Prentice Hall, v. 12, p. 15-17, 2003.
- [13] NISHIKAWA, Hiroaki. A first-order system approach for diffusion equation. I: Second-order residual-distribution schemes. Journal of Computational Physics, v. 227, n. 1, p. 315-352, 2007.
- [14] ARENALES, Selma; DAREZZO, Artur. Cálculo numérico: aprendizagem com apoio de software. Cengage Learning, 2008.
- [15] COLEY, David A. An introduction to genetic algorithms for scientists and engineers. World Scientific Publishing Co Inc, 1999.
- [16] BOMFIM JUNIOR, Florisvaldo Cardozo. Modelagem de Funções de Transferência de Plantas Industriais em Malha Aberta e Fechada utilizando Algoritmos Genéticos. 2017. 51 f. Dissertação (Mestrado em Engenharia Elétrica)- Universidade Federal de Uberlândia, Uberlândia, 2017. Programa de Pós-graduação em Engenharia Elétrica.