

Planejamento de Rota via Algoritmo Genético para um Robô Lego EV3

Filipe G. S. Dameto¹, João Paulo L. S. Almeida¹, André L. S. Moscato¹, Héber R. F. Morais¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Paraná - Campus Jacarezinho
Caixa Postal 86.400-000 – Jacarezinho – PR – Brasil

filipefilipedameto@gmail.com, joao.almeida@ifpr.edu.br,
andre.moscato@ifpr.edu.br, heber.morais@ifpr.edu.br

Abstract. *Robotics is a multidisciplinary field that faces critical challenges in determining efficient routes for mobile robots in various environments. The main objective of this work is to explore and validate a route planning solution for robots on the Lego EV3 platform using a Genetic Algorithm (GA). The route generated by the GA was used in the Lego robot, and for the robot's self-localization in the navigation environment, light detection sensors were used to identify auxiliary markings. The results demonstrated that the GA was able to determine routes effectively. Thus, the mobile robot was able to localize itself in the environment and follow the path determined by the GA.*

Resumo. *A robótica é um campo multidisciplinar que enfrenta desafios críticos na determinação de rotas eficientes para robôs móveis em diversos ambientes. O objetivo principal deste trabalho é explorar e validar uma solução de planejamento de rota em robôs da plataforma Lego EV3, via Algoritmo Genético (AG). A rota gerada pelo AG foi utilizada no robô Lego e, para fins de auto-localização do robô no ambiente de navegação, foram utilizados sensores de detecção de luminosidade para a identificação de marcações auxiliadoras. Os resultados demonstraram que o AG conseguiu determinar rotas com eficácia. Dessa forma, o robô móvel foi capaz de se localizar no ambiente e de cumprir o caminho determinado pelo AG.*

1. Introdução

A robótica, como uma das ferramentas da sociedade contemporânea, tem evoluído rapidamente ao longo das últimas décadas, combinando conhecimentos de diversos campos de estudo (como ciência da computação, engenharia mecânica/elétrica e diversas outras) para desenvolver sistemas autônomos capazes de interagir e se adaptar ao ambiente circundante. Desde sua utilização em processos industriais até sua presença em ambientes domésticos e educacionais, os robôs estão se tornando progressivamente mais avançados e aptos a desempenhar tarefas complexas. Dentro desse contexto, o planejamento de rota se destaca como um dos desafios mais relevantes, pois envolve a definição de um percurso eficaz e mais eficiente para um robô se deslocar entre dois pontos, evitando barreiras e otimizando tempo e recursos [Yang, Miao e Wong 2017].

O desafio do planejamento de trajetória é uma das principais questões enfrentadas no domínio da robótica móvel. Para resolver esse problema, é essencial que o robô consiga processar informações sobre o ambiente e tomar decisões com base nas informações fornecidas (via sensores ou até mesmo pelo usuário), de modo a evitar

colisões e garantir que o caminho selecionado seja o mais eficiente possível. Dessa forma, uma das plataformas que possibilitam essa implementação é o Lego Mindstorms®, uma ferramenta educacional amplamente utilizada no ensino de robótica, que também serve como uma base eficaz para a avaliação de algoritmos inteligentes em um ambiente controlado. A utilização de um Algoritmo Genético (AG) embarcado no robô Lego representa uma abordagem promissora para aprimorar sua capacidade de encontrar soluções otimizadas para o planejamento de trajetória em espaços de navegação [Luna, et al. 2012].

O principal objetivo deste trabalho é investigar o problema do planejamento de trajetória para robôs Lego por meio da aplicação de um Algoritmo Genético (AG), enfatizando a eficiência e a viabilidade da solução dentro de um cenário laboratorial. A contribuição deste estudo reside na adaptação e implementação de um AG embarcado no robô Lego, demonstrando sua eficácia na resolução do problema de planejamento de trajetória em um ambiente estático, considerando as limitações de hardware existentes. Espera-se que essa abordagem não apenas agregue valor à área de robótica educacional, mas também forneça ideias promissoras para aplicações mais amplas na robótica móvel aplicada ao setor industrial.

Este trabalho está estruturado da seguinte forma: a Seção 2 (Fundamentação Teórica) apresenta os principais conceitos necessários para a realização da pesquisa; a Seção 3 (Metodologia) descreve os métodos de implementação do planejamento de trajetória por meio do Algoritmo Genético, bem como a navegação do robô móvel; a Seção 4 (Resultados e Discussões) apresenta uma solução de trajetória obtida pela estratégia adotada neste estudo; e, por fim, a Seção 5 (Considerações Finais) expõe as principais conclusões e as perspectivas para trabalhos futuros.

2. Fundamentação Teórica

2.1 Robótica Móvel e Planejamento de Rota

A definição da rota de um robô, conhecida como planejamento de rota, tem a função de determinar os caminhos mais eficientes e seguros para que ele atinja seus objetivos. Esse procedimento requer uma avaliação detalhada de variáveis como a existência de obstáculos, a eficiência do percurso e o tempo de execução, sendo fundamental para garantir o desempenho adequado dos sistemas robóticos.

Os sistemas inteligentes são fundamentais na robótica educacional [Sullivan e Heffernan 2016], permitindo a experimentação de algoritmos avançados em plataformas como LEGO EV3 e NXT. Apesar das limitações de hardware, essas ferramentas possibilitam a implementação de soluções para navegação autônoma, utilizando sensores e estratégias de controle. Entre essas abordagens, os algoritmos genéticos destacam-se na otimização de rotas, permitindo ajustes dinâmicos e adaptação a incertezas do ambiente. Inspirados na seleção natural, esses algoritmos geram múltiplas soluções e refinam rotas de forma iterativa. Sua aplicação permite que os alunos não apenas compreendam conceitos teóricos, mas também desenvolvam sistemas inteligentes para problemas reais. Assim, a robótica educacional se torna um campo de experimentação para inovações tecnológicas. Essas técnicas, além de aprimorar a aprendizagem, preparam os estudantes para desafios na robótica móvel aplicada a contextos acadêmicos e industriais, onde soluções adaptativas são cada vez mais necessárias.

2.2 Algoritmo Genético

A operação de um Algoritmo Genético (AG) baseia-se em um modelo evolucionário, no qual a evolução de um indivíduo ou cromossomo, que representa uma solução para o problema, ocorre por meio da seleção dos mais aptos para a reprodução e transmissão de seus genes. Essa abordagem tem sido amplamente empregada em diversos domínios da robótica, incluindo o planejamento de trajetória [Almeida, Arruda e Neves-Jr 2017].

O funcionamento de um AG pode ser visualizado por meio do fluxograma da Figura 1, seguindo as etapas a seguir:

- a) Inicialização: No primeiro estágio, uma população inicial é gerada, composta por cromossomos, que por sua vez são compostos de genes, cada um representando uma solução possível para o problema.
- b) Seleção: Os indivíduos mais bem adaptados são escolhidos, formando pares que serão utilizados na próxima etapa.
- c) Cruzamento: Nessa fase, ocorre a combinação dos cromossomos selecionados, gerando novos indivíduos que mesclam soluções distintas para o problema.
- d) Mutação: Existe uma pequena probabilidade de que os cromossomos sofram alterações aleatórias, promovendo diversidade na população (variabilidade genética) e prevenindo a convergência prematura para soluções subótimas.
- e) Critério de Parada: Se algum cromossomo atingir os critérios estabelecidos para a solução do problema, o algoritmo é encerrado. Caso contrário, o ciclo recomeça a partir da etapa de cruzamento, garantindo a continuidade da evolução da população.



Figura 1 - Fonte: adaptado de Cortes (2005 Apud Catarina, 1999)

3. Metodologia

Foi desenvolvido um Algoritmo Genético (AG) com o objetivo de otimizar a rota de um robô móvel, permitindo seu deslocamento da posição inicial até um destino predefinido [MORAIS, et al. 2023]. Para a codificação do AG, adotou-se a modelagem do ambiente em uma grade subdividida em células, baseada em uma matriz bidimensional de coordenadas (x, y). Dessa forma, o AG pode calcular uma rota eficiente e otimizada em termos de distância percorrida, respeitando as restrições impostas pelo ambiente, como por exemplo: obstáculos ou pontos de passagem obrigatória.



Figura 2 - Robô utilizado na pesquisa

Para a implementação do sistema de planejamento de rota e navegação, foi construído um robô móvel utilizando o kit de robótica LEGO® EV3, conforme ilustrado na Figura 2. A montagem e a configuração do robô foram realizadas no laboratório *maker* GaJac, do Instituto Federal do Paraná – Campus Jacarezinho (IFPR).

A programação do Algoritmo Genético e do sistema de mobilidade do robô foi conduzida externamente ao hardware da plataforma LEGO, ficando a cargo do robô apenas a execução do trajeto planejado. As próximas subseções detalham a estrutura do AG desenvolvido, bem como as estratégias de navegação adotadas pelo robô móvel para percorrer a rota definida.

3.1 Planejamento de Rota via Algoritmo Genético

O Algoritmo Genético (AG) empregado tem como finalidade otimizar o trajeto percorrido pelo robô móvel entre dois pontos do ambiente. Para tal, foram definidos os seguintes elementos e operadores:

- a) Cromossomo (indivíduo): representa uma solução viável para o problema e é estruturado como um vetor de posições. Cada posição do vetor indica um comando de manobra que o robô deve executar sequencialmente (genes). Os comandos possíveis incluem: “esquerda”, “cima”, “direita”, “baixo” e “parado”, sendo representados numericamente para facilitar o processamento computacional. Esses comandos definem o deslocamento do robô na matriz que representa o ambiente.
- b) Função de aptidão (*fitness function*): a qualidade de cada solução é avaliada por meio de uma função, definida na equação (1). Essa função considera diversos

- fatores para determinar a eficiência da rota planejada:
- c) D_{xy} :Distância entre a posição final do robô e o destino.
 - d) M_r :Constante que penaliza soluções com muitas mudanças de direção, destacando trajetórias mais retilíneas.
 - e) O_a : Constante que valoriza soluções que levam o robô ao objetivo, priorizando rotas eficazes.
 - f) A_t : Fator que avalia se o robô permanece dentro dos limites do tabuleiro, favorecendo trajetórias factíveis; também avalia se o robô cumpriu com as exigências de obstáculos e passagens obrigatórias.
 - g) R_p : Constante que beneficia soluções nas quais o robô atinge o destino com um menor número de movimentos e permanece parado ao final.
 - h) Essa função de aptidão permite ao AG selecionar as melhores soluções ao longo das gerações, refinando continuamente as trajetórias e garantindo a otimização do deslocamento do robô.

$$fit = \frac{1}{D_{xy} \cdot 5} \cdot Mr \cdot Oa \cdot A_t \cdot Rp \quad (1)$$

- i) O operador de seleção escolhe de forma aleatória, segundo o tamanho da população, 15 cromossomos, para serem avaliados pelo método de nome “torneio” [Gomide, Arce e Silva 2009]. Nesse modelo, os indivíduos escolhidos serão avaliados pelo seu fit , separando os dois melhores e os enviando para o próximo processo.
- j) Operador de cruzamento é o momento em que os cromossomos vencedores do torneio são passados para a próxima parte do processo, de forma que seus genes (posições) são mesclados, assim como na Figura 4. Esse processo garante que os cromossomos escolhidos mantenham seus desempenhos e aumentem a variabilidade genética da população.

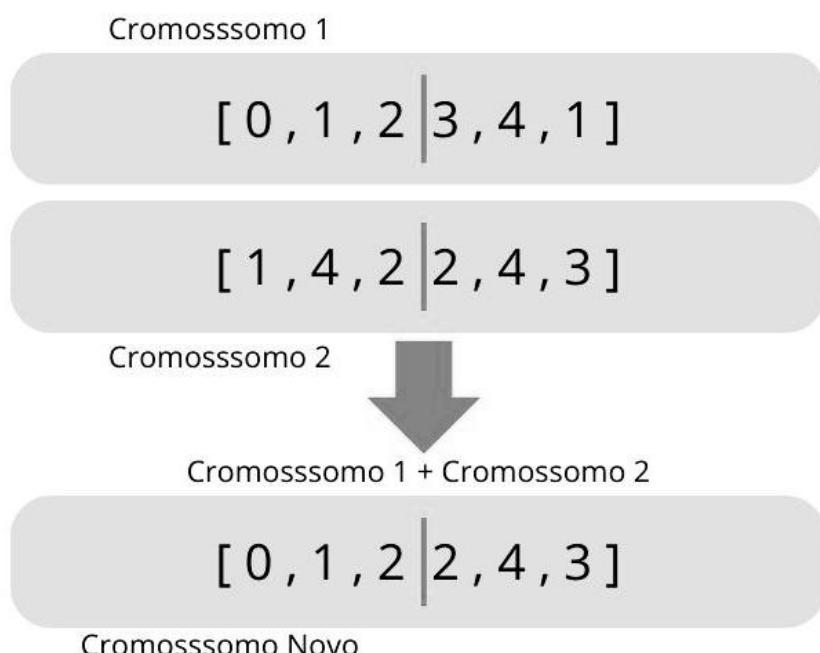


Figura 4 - Exemplo de cruzamento entre cromossomos

k) No operador de mutação, os novos indivíduos possuem uma chance de 5% para serem modificados. Quando ocorre, um gene aleatório, exceto o primeiro e o último (já que podem representar um ponto obrigatório dentro do sistema), é modificado para outro movimento qualquer, com o intuito de aumentar a diversidade da população, assim como na Figura 5.



Figura 5 - Exemplo de mutação entre cromossomos

3.2 Navegação do Robô Móvel

Uma vez que o Algoritmo Genético gera uma sequência de ações que o robô deve executar para atingir seu objetivo, ele precisa realizar esses movimentos de forma ordenada e progressiva. Para isso, o robô interpreta o cromossomo de solução e executa os comandos especificados, garantindo a correta execução da rota planejada.

Para que a navegação ocorra de forma eficaz e eficiente, o robô deve identificar quando cada ação de movimento foi concluída com sucesso. Nesse sentido, as linhas divisórias das células quadriculadas do ambiente (conforme ilustrado na Figura 1) funcionam como delimitadores para a verificação desses movimentos. O robô conta com um giroscópio e sensores de luminosidade acoplados ao seu hardware, sendo que o sensor de luminosidade, apontado para o solo, permite a identificação da transição entre células. Isso garante que cada deslocamento planejado (representado por um gene do cromossomo de solução) seja devidamente executado antes de passar para o próximo comando.

Para simplificar a execução da rota, o robô inicia seu trajeto apenas se estiver alinhado com uma orientação de referência, definida virtualmente no canto inferior esquerdo do ambiente. Além disso, ao final de cada movimento, o robô realiza obrigatoriamente uma manobra de realinhamento da sua orientação (conforme indicado na Figura 6, em azul). Essa estratégia evita a necessidade de ajustes angulares complexos durante a execução dos movimentos planejados pelo Algoritmo Genético, garantindo maior precisão na navegação.

4. Resultados e Discussões

Para a validação do Algoritmo Genético (AG) como planejador de rotas, um experimento foi conduzido a partir do caso apresentado na Figura 7, em que o robô, de sua posição inicial, deve alcançar o seu objetivo, demarcado com um "X" no ambiente

(linha 5, coluna 5). Para isso, o AG é executado e na Figura 6 é mostrada a evolução da função *fit* (Eq. (1)) do melhor, da média e do pior indivíduo de cada geração de população. Possivelmente, a existência de obstáculos (marcados com um x, linha 4 e coluna 3, linha 4 e coluna 4) deve agravar a qualidade dos indivíduos por geração, de forma que o objetivo seja cumprido com maior necessidade de tentativas.

Sendo assim, o planejamento de rota é realizado e executado pelo robô, conforme é mostrado na sequência de quadros (*frames* advindos de uma gravação de vídeo) da Figura 8. Neste caso, a seguinte rota foi calculada pelo AG: [2, 2, 1, 1, 2, 2] ou [Direita, Direta, Cima, Cima, Direita, Direita]. Além disso, é possível notar que a cada movimento o robô se encontra alinhado com a orientação de referência.




Figura 6 - Gráfico de cromossomos

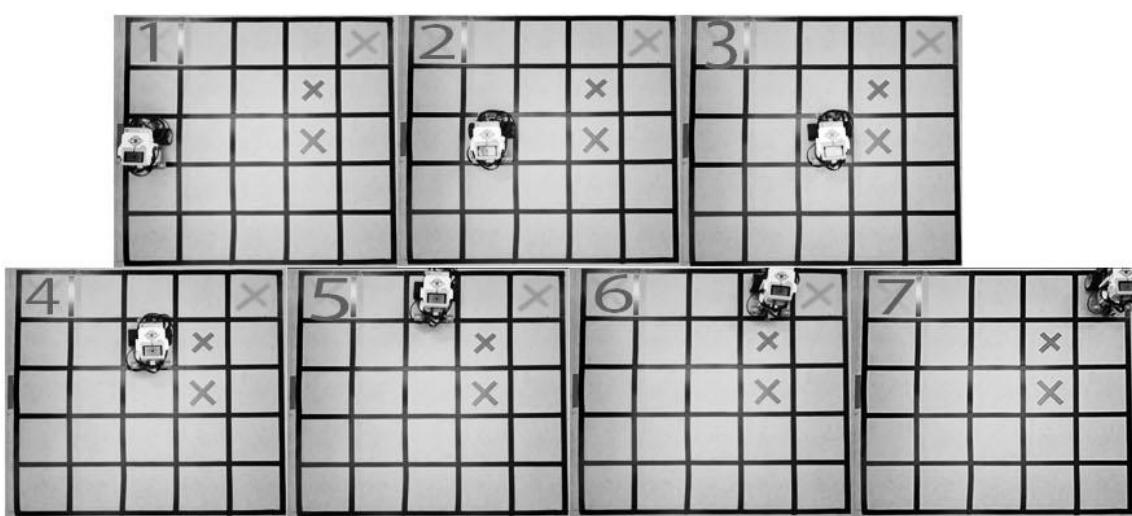


Figura 7 - Execução da rota gerada pelo AG

5. Considerações Finais

Considerando todo o trabalho desenvolvido, a utilização de um Algoritmo Genético a partir de *hardware* externo e aplicando a rota ao Lego Mindstorms® EV3, *a priori* como Planejador de Rota em ambientes controlados, se mostrou eficaz e eficiente quanto à função de alcançar o objetivo. Por outro lado, a utilização do Algoritmo Genético em conjunto ao Lego Mindstorms® EV3 demonstrou que é possível aplicar sistemas inteligentes dessa portabilidade (considerando sua alta exigência em *hardware*) em microcontroladores de médio desempenho de processamento. A variação de tempo experimental para a execução de todo o aparato lógico necessário (código e recursos exigidos), quando executado no robô de forma única (sem *hardware* externo) demonstrou determinada resistência, com tempo de execução próximo a 5 minutos. Contudo, ao passo que a portabilidade da codificação foi encarregada a um *hardware* externo, essa resistência foi rapidamente dissipada, transformando o tempo de execução em aproximadamente 10 segundos.

Considerando essa observação, deve-se levar em conta que toda a investigação científica aplicada ao projeto é, possivelmente, um recurso interessante ao analisar as necessidades e aplicações disponíveis no que tange o Planejamento de Rota via sistemas inteligentes. Como missões futuras, deve-se provavelmente conterem a aplicação de diferentes algoritmos inteligentes para uma comparação mais aprofundada e prática, podendo tirar conclusões mais precisas acerca da qualidade de diferentes métodos de busca por pontos dinâmicos em um ambiente controlado.

References

- CORTES, M. B. S. Introdução à otimização. In: II Jornada de Estatística de Maringá. Mini-curso: Introdução à otimização. Maringá: UEM, Departamento de Estatística, 1999.
- DE ALMEIDA, J. P. L. S.; DE ARRUDA, L. V. R.; NEVES-JR, F. Planejamento de rota por meio de algoritmo genético para um enxame de robôs. 2017.
- GOMIDE, L. R.; ARCE, J. E.; SILVA, A. C. L. Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção. Cerne, v. 15, n. 4, p. 460-467, 2009.
- LUNA, J. A. G.; SÁNCHEZ, R. E. A.; PINZÓN, L. D. J. Búsqueda de la ruta óptima mediante los algoritmos: genético y dijkstra utilizando mapas de visibilidad. Scientia et technica, v. 17, n. 51, p. 107-112, 2012.
- MORAIS, H. R. F.; ANGELINI, C. E.; MOSCATO, A. L. S.; ALMEIDA, J. P. L. S.; ARRUDA, L. V. R. Planejamento de Rota por Algoritmo Genético em Um Sistema Ciber-Físico. Simpósio Brasileiro de Automação Inteligente, Manaus. 2023.
- SULLIVAN, F. R.; HEFFERNAN, J. Robotics and education: New tools, new learning. Journal of Research on Technology in Education, 106-128. 2016.
- YANG, C; WONG, D.; MIAO, Q. Advanced Geoinformation Science. 1th. Boca Raton: CRC Press, 2017.