

UTILIZAÇÃO DO CONTROLADOR ILQR PARA NAVEGAÇÃO DE ROBÔS MÓVEIS 4WD EM CAMPOS AGRÍCOLAS

Francisco Affonso Pinto

Matheus Gasparino Valverde

Marcelo Becker

Escola de Engenharia de São Carlos/Universidade de São Paulo

francisco.affonso02@usp.br; mvalve2@illinois.edu; becker@sc.usp.br

Objetivos

A navegação de robôs móveis em terrenos agrícolas apresenta desafios significativos devido à natureza acidentada desses ambientes. Nessas condições, a busca por trajetórias ideais se destaca como uma estratégia altamente eficaz, pois permite avaliar tanto a autonomia do robô quanto a suavidade de sua operação.

Nesse contexto, o controlador iLQR (*iterative linear quadratic regulator*) emerge como uma escolha altamente promissora. Este controlador é o resultado de um problema de otimização, especialmente adequado para lidar com sistemas não lineares. Não sendo muito explorado na literatura, é de grande interesse avaliar o desempenho do controlador com métodos difundidos.

Métodos e Procedimentos

No contexto de um sistema de navegação completo, o controlador desempenha um papel crucial ao receber um plano de trajetória e, em seguida, relacioná-lo com o estado estimado atual do robô, a fim de gerar ações de controle para execução da trajetória planejada. Para implementar o controlador iLQR e cumprir essa tarefa, é necessário seguir várias etapas para

definir o problema de otimização e compreender como ele gera ações de controle.

Nesse trabalho, foi utilizado o robô TerraSentia, cedido pela EarthSense, por se tratar de um robô com um sistema de tração independente nas quatro rodas (4WD) específico para aplicações no campo.



Figura 1: TerraSentia

A dinâmica do robô pode ser expressa de forma discreta e não linear como desenvolvido para robôs móveis 4WD em [1]:

$$e_{(k+1)} = f(e_k, u_k) = A_k e_k + B_k u_k \quad (1)$$

onde, A_k e B_k são derivadas do modelo.

Com isso, podemos definir a função de custo quadrática linear que será utilizada:

$$J = \frac{1}{2} \sum e_k^T Q_k e_k + u_k^T R_k u_k \quad (2)$$

onde, Q_k e R_k são as matrizes de custo.

Para concluir o problema de otimização, apresentamos o *cost-to-go* para o estado final:

$$V_n(e_N) = \frac{1}{2} e_N^T Q_f e_N \quad (3)$$

onde, Q_f é a matriz de custo final.

Após a formulação do problema, podemos descrever como o iLQR emprega a programação dinâmica em suas etapas de *backward* e *forward pass*, para determinar a ação de controle; tendo a escolha das matrizes de peso para ajustar o comportamento do controlador[2].

No estágio *backward*, o algoritmo calcula iterativamente os gradientes da função de custo em relação aos estados e controles.

No *forward pass*, o algoritmo simula a trajetória resultante das ações de controle previamente calculadas, computando o custo total ao longo do horizonte de tempo.

Resultados

Para simular o sistema do robô, foi utilizado um ambiente no Gazebo, com o desenvolvimento de todos os sistemas no ROS (Robot Operating System).

Com o objetivo de isolar variáveis de outras seções de um sistema de navegação, os alvos foram escolhidos arbitrariamente e não foi utilizado estimador de estado.

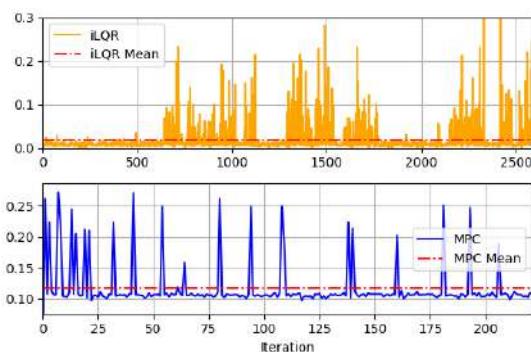


Figura 2: Gasto computacional do iLQR e MPC

A fim de determinar em quais situações o iLQR se revela a melhor opção, realizou-se uma comparação dos seus resultados com os do MPC (*model predictive control*), conforme detalhado em [3].

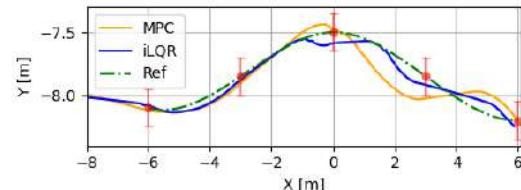


Figura 3: Resultados da trajetória do iLQR

Conclusões

Com base nos resultados apresentados, fica evidente que o iLQR proporciona trajetórias satisfatórias para aplicações em ambientes agrícolas. No entanto, é importante notar que o tempo necessário para percorrer essas trajetórias tende a ser maior em comparação com controladores mais robustos, como o MPC. Por fim, o iLQR emerge como uma alternativa atraente em situações onde há restrições de *hardware*.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo auxílio financeiro concedido através da Bolsa de Iniciação Científica (2022/03339-8).

Referências

- [1] E. Kayacan and G. Chowdhary, "Tracking error learning control for precise mobile robot path tracking in outdoor environment," CoRR, vol. abs/2103.11282, 2021.
- [2] B. E. Jackson, "AI-ilqr tutorial," 2019.
- [3] F. A. Pinto, F. Tommaselli, M. V. Gasparino, and M. Becker, "Navigating with finesse: Leveraging neural network-based lidar perception and ilqr control for intelligent agriculture robotics," in SBR-LARS 2023, oct 2023.