

ABORDAGEM DE PATRULHAMENTO PARA MISSÕES COM MÚLTIPLOS VANTS E PREOCUPAÇÃO ENERGÉTICA

KRISTOFER STIFT KAPPEL¹; TAUÃ CABREIRA MILECH²; LISANE BRISOLARA DE BRISOLARA³; PAULO ROBERTO FERREIRA JÚNIOR⁴

¹Universidade Federal de Pelotas – kskappel@inf.ufpel.edu.br

²Universidade Federal de Pelotas – tmcabreira@inf.ufpel.edu.br

³Universidade Federal de Pelotas – lisane@inf.ufpel.edu.br

⁴Universidade Federal de Pelotas – paulo@inf.ufpel.edu.br

1. INTRODUÇÃO

Os Veículos Aéreos Não Tripulados (VANTs) tem sido cada vez mais empregados em diversos domínios de aplicação. São veículos sem pilotos a bordo, usualmente controlados remotamente por um piloto em solo, missão pré programada ou sistemas inteligentes.

O problema de Patrulhamento consiste em, constantemente, visitar e revisitar uma área em tempos regulares para que o agente possa realizar atividades como supervisão e inspeção do local. Técnicas de patrulhamento em solo podem ser extendidas para coberturas com VANTs, porém certos cuidados devem ser tomados em questões como manobrabilidade, restrições energéticas, restrições de carga, dentre outros.

Métodos de Busca em Tempo Real (MBTR) fazem o planejamento da rota durante a missão. Tipicamente os MBTR empregam uma busca local pela área vizinha menos visitada. Como tem baixo custo computacional podem ser propostos para problemas de patrulhamento com veículos autonomos uma vez que energia é uma limitação (KOENIG et al., 2001).

Padrões de vôo baseados em formas geométricas como espiral ou vai-e-volta tem sido utilizados para tarefas de cobertura (ANDERSEN, 2014). Mas esses padrões são facilmente reconhecíveis e não indicados para missões de patrulhamento e vigilância.

2. METODOLOGIA

Para realizar os MBTRs o cenário é dividido em células, com isso a vizinhança de Von Neumann é adotada para busca e movimentação entre essas células. Em geral os MBTR trabalham com um valor associado a cada célula do cenário, chamado de *u-value*, o qual denota o número de vezes que uma célula já foi visitada.

O *u-value* representa marcas de feromônios deixadas pela movimentação dos veículos no cenário, uma analogia à maneira como formigas se comunicam. Feromônios são usados como canal indireto de comunicação entre os veículos nesse caso.

Analizando os *u-values* dos vizinhos o agente pode decidir para onde ir, o objetivo é andar pelas áreas não exploradas ou menos frequentemente exploradas no mapa. O que diferencia os MBTRs utilizados é, basicamente, o modo de atualização da célula no movimento. O Node Counting (NC) só adiciona uma unidade a célula atual $u(s) := u(s) + 1$ (PIRZADEH et al., 1990). O Learning Real-Time A* (LRTA*) usa o *u-value* da próxima célula como referência para atualizar a atual $u(s) := u(next(s)) + 1$ (KORF, 1990). Já o Thrun's Value Update Rule, faz uma comparação entre o maior do NC ou do LRTA* antes de atribuir $u(s) := max(u(s),$

$u(next(s))) + 1$ (THRUN, 1992). O Wagner's Value Update Rule (WVUR), por sua vez só atualiza se o valor da célula atual for menor do que o da próxima *if* $u(s) <= u(next(s))$ *then* $u(s) := u(s) + 1$ (WAGNER et al., 1997). Quando há empate a escolha é aleatória entre as células com *u-values* empatados.

A partir das heurísticas citadas, uma nova abordagem foi proposta. O Node Counting Drone (NC-Drone) têm como premissa seguir em linha reta nos casos de empate, se possível. Num cenário de patrulhamento real com VANTs utilizando os MBTRs citados, cada curva significa uma manobra de virada do drone, o qual demanda mais tempo, uma vez que o drone tem que reduzir a velocidade, virar e acelerar novamente, o qual consome mais energia, reduzindo assim o tempo útil da missão (DI FRANCO et al., 2016).

A partir do NC-Drone duas outras abordagens foram propostas, uma versão centralizada, onde o VANT é capaz de sensoriar e trocar informações pelo ambiente com os feromônios citados anteriormente. Para implementar uma abordagem como essa em missões reais uma estação de controle deve ser utilizada para comunicar os VANTs e guardar o estado do mapa a cada momento.

A segunda abordagem proposta é uma versão descentralizada do NC-Drone. Nessa versão cada veículo tem um mapa interno o qual atualiza a cada instante. Uma vez que está próximo de outro veículo os dois trocam informações e atualizam as matrizes atuais. Foram avaliados três diferentes métodos de mesclar essas informações das matrizes: MAX, compara cada elemento na matriz e mantém os maiores valores, AVG, o qual faz uma média dos valores e RESET, onde um MAX é aplicado mas sempre que há uma matriz somente com áreas cobertas essa matriz é preenchida com zeros.

A partir disso foi testada uma abordagem de combinar as informações apenas para tomada de decisões, os VANTs guardam a matriz mais recentemente atualizada de cada outro veículo e quando uma decisão precisa ser tomada os vizinhos da região atual de cada matriz são somados e o menor é escolhido para ser o próximo, essa abordagem foi chamada de MULTI.

Para as simulações foi utilizado o Netlogo. O cenário tem tamanho 50 x 50 células com 4 veículos simultâneos sendo disparados em um tick de diferença. Foram testadas trinta vezes os algoritmos com tempo de, 10,000, 15,000 e 20,000 ticks.

Para medir a performance dos algoritmos foram utilizados as seguintes métricas: Média Quadrática dos Intervalos (MQI), que mede a regularidade do tempo de visita em uma mesma célula, Desvio Padrão das Frequências (DPF) (SAMPAIO et al., 2016), que apresenta o quanto uniformes são as visitas no cenário, Número de Manobras de Curva (NMC) e Número de Coberturas Completas (NCC).

3. RESULTADOS E DISCUSSÃO

O primeiro teste foi o NC-Drone Centralizado contra os MBTR citados (NC, LRTA*, TVUR e WVUR). Todas as abordagens compartilham as informações pelo ambiente lendo e escrevendo nos células.

No MQI o NC-Drone supera todas as outras abordagens, ele tem uma performance 5% melhor do que a segunda abordagem, o TVUR e 7% comparado com o NC original.

Quanto ao DPF, o NC-Drone Centralizado é superior aos demais com 10k, 15k e 20k ciclos, com exceção do WVUR e do LRTA*, este com 15k ciclos, o qual é muito similar. Com relação ao NC e o ao TVUR, o NC-Drone Centralizado é, por volta de 11%, melhor comparado com ambas as abordagens.

Como era de se esperar, no NMC o NC-Drone é de três a quatro vezes menor do que as outras abordagens, escolher sempre a célula à frente em caso de empates reduz o número de curvas o que implica em menor consumo energético.

No NCC os resultados são todos similares, mas o NC-Drone Centralizado só fica atrás do TVUR, o qual é uma troca válida em missões de patrulhamento, considerando a distribuição uniforme de visitas e menor consumo de energia.

No segundo experimento foram testadas as variações do NC-Drone Descentralizado (Sem Comunicação, MULTI, MAX, AVG e RESET).

No MQI, MAX e AVG tem os melhores resultados enquanto MULTI tem os piores. Já no DPF o MULTI assumo o topo com as visitas mais uniformes dentre as viariações. As técnicas de fusão de informações não são capazes de distribuir igualmente as visitas pelas células. Até o Sem Comunicação supera os outros métodos. O Reset foi pensado para eliminar as distorções ao longo do tempo na matriz, mas apresenta os piores resultados.

No NMC o Sem Comunicação apresenta os melhores resultados em 10k e 15k, mas com 20k o RESET passa ele. Ambos tem falta de informações “completas”, trocar informações causa menos empates, o que pode aumentar o número de curvas.

O MULTI tem resultados interessantes no NCC quase obtendo valores próximos ao do Centralizado.

4. CONCLUSÕES

Este trabalho apresenta um Método de Busca em Tempo Real com preocupação energética para o problema de patrulhamento com múltiplos VANTs. Uma versão centralizada é comparada com as estratégias baseadas em feromônios a qual reduz o número de curvas, impactando positivamente no consumo energético. Porém essas estratégias centralizadas nem sempre são possíveis em cenários reais devido a constantes comunicações necessárias entre a base e os veículos. Uma proposta descentralizada é apresentada em que os VANTs salvam uma cópia da matriz do cenário e trocam informações com outros VANTs em um raio de comunicação.

Como trabalhos futuros pretendemos melhorar as performances de coberturas buscando técnicas que avaliem o cenário por inteiro. Também pretendemos implementar e comparar as técnicas descentralizadas em voôs reais.

5. REFERÊNCIAS BIBLIOGRÁFICAS

KOENIG, Sven; LIU, Yixin. Terrain coverage with ant robots: a simulation study. In: **Proceedings of the fifth international conference on Autonomous agents**. ACM, 2001. p. 600-607.

PIRZADEH, Amir; SNYDER, Wesley. A unified solution to coverage and search in explored and unexplored terrains using indirect control. In: **Robotics and Automation, 1990. Proceedings., 1990 IEEE International Conference on**. IEEE, 1990. p. 2113-2119.

ANDERSEN, Håvard Lægreid. **Path planning for search and rescue mission using multicopters**. 2014. Dissertação de Mestrado. Institutt for teknisk kybernetikk.

KORF, Richard E. Real-time heuristic search. **Artificial intelligence**, v. 42, n. 2-3, p. 189-211, 1990.

THRUN, Sebastian B. Efficient exploration in reinforcement learning. 1992.
WAGNER, I.; LINDENBAUM, Michael; BRUCKSTEIN, A. On-line graph searching by a smell-oriented vertex process. In: **Proceedings of the AAAI Workshop on On-Line Search**. 1997. p. 122-125.

SAMPAIO, Pablo A.; SOUSA, Rodrigo Da S.; ROCHA, Alessandro N. New Patrolling Strategies with Short-Range Perception. In: **Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR), 2016 XIII Latin American**. IEEE, 2016. p. 157-162.

DI FRANCO, Carmelo; BUTTAZZO, Giorgio. Coverage path planning for UAVs photogrammetry with energy and resolution constraints. **Journal of Intelligent & Robotic Systems**, v. 83, n. 3-4, p. 445-462, 2016.