

Impacto da variação da quantidade de caminhos ótimos no LRTA-Star cooperativo

Impact of varying the number of optimal paths on the cooperative LRTA-Star

RESUMO

Luan Carlos Klein
luanklein@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil

Cesar Augusto Tacla
tacla@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil

A utilização de caminhos e rotas ótimas em sistemas multiagente é de fundamental importância. Quanto mais caminhos ótimos disponíveis, mais eficiente o sistema tende a ser, pois o número de colisões entre os agentes tende a diminuir. Diante disso o LRTA-Star (*Learning Real Time A-Star*) surge como uma opção que possibilita encontrar todos os caminhos ótimos disponíveis. O presente artigo estuda como o aumento da quantidade de caminhos a serem encontrados impacta nas distâncias percorridas pelos agentes até o momento em que eles sejam encontrados, utilizando o LRTA-Star de maneira cooperativa em ambientes estáticos. Através de experimentos realizados observou-se que existe uma relação entre as quantidades de agentes, caminhos ótimos a serem encontrados e as distâncias percorridas pelos agentes. A quantidade de movimentos totais e individuais se comportam como curvas matemáticas, sendo uma curva linear e uma exponencial decrescente, respectivamente. Também se observou que a quantidade de caminhos ótimos a serem encontrados tem pequena influência nas distâncias percorridas pelos agentes. Isso significa que após encontrar um caminho ótimo, os demais podem ser encontrados com uma pequena quantidade extra de movimentos por parte dos agentes.

PALAVRAS-CHAVE: Agentes. Aprendizado cooperativo. Desempenho de sistemas.

ABSTRACT

Recebido: 19 ago. 2020.

Aprovado: 01 out. 2020.

Direito autorial: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



The use of optimal paths and routes in multi-agent systems is of fundamental importance. The greater the number of available optimal paths, the more efficient the system tends to be, as the number of collisions between agents tends to decrease, and the traveled distances remain optimal. Therefore, LRTA-Star (*Learning RealTime A-Star*) appears as an option that makes it possible to find all the optimal paths. This article studies how increasing the number of paths to be found impacts on the distances traveled by the agents until the moment they are found, using the LRTA-Star cooperatively in static environments. It was observed through experimentation that there is a relationship between the number of agents, the number of optimal paths to be found, and the distances traveled by the agents. The number of total and individual movements behave like mathematical curves, being a linear curve and a decreasing exponential, respectively. It was also observed that the number of optimal paths to be found has little influence on the distances traveled by the agents. This means that after finding the first optimal path, the others can be found with a small extra amount of movement by the agents.

KEYWORDS: Agents. Cooperative learning. System performance.

INTRODUÇÃO

O conhecimento de caminhos e rotas ótimas é fundamental em ambientes onde o tempo de deslocamento é relevante. Alguns exemplos são cenários de jogos, armazéns automatizados, carros autônomos e cenários de carga e descarga (MA et al., 2016; SIGURDSON, 2018; HÖNING et al., 2019). Nesses cenários há a presença de diversos agentes ao mesmo tempo e a comunicação entre eles é possível, porém não obrigatória.

O MAPF (*Multi-Agent Path Finding*) é uma área de estudo que consiste em encontrar os caminhos para diversos agentes em um mesmo ambiente de maneira que eles não colidam entre si (FELNER et al., 2017; STERN et al., 2019; STERN, 2019). A cooperação entre agentes para a descoberta de caminhos ótimos é um tema que também já foi discutido por (STANDLEY, 2010).

Entretanto, na maioria dos cenários, os agentes não conhecem os caminhos ótimos e cabe a eles encontrarem. Devido a isso, descobrir os caminhos da maneira mais rápida e eficiente possível é fundamental. Aumentar a quantidade de agentes na busca pelos caminhos ótimos diminui o tempo para encontrá-los ao mesmo tempo que eleva o custo da mesma tarefa. Assim, entender a relação entre tempo, consumo de recursos, quantidade de agentes e de caminhos ótimos disponível se faz fundamental para obter o máximo de desempenho em um sistema.

Um dos algoritmos para descoberta de caminhos ótimos em tempo real, proposto por Korf (1990), é o LRTA* (*Learning Real Time A**). O seu propósito é intercalar planejamento e ação, melhorando o caminho (reduzindo a distância percorrida) com a repetição de execuções. Esse algoritmo, em essência, é realizado de maneira individual, sendo executado e planejado por apenas um agente. Entretanto, através de algumas adaptações no algoritmo, é possível utilizá-lo de maneira coletiva, isto é, utilizar múltiplos agentes no mesmo cenário, compartilhando das mesmas informações, buscando alcançar um mesmo objetivo.

Segundo Zafar and Baig (2012), sistemas multiagente podem ser utilizados para explorar ambientes desconhecidos e encontrar os caminhos ótimos de maneira eficiente utilizando algoritmos de busca. O paradigma de resolução de problemas chamado *organizational problem solving* (resolução de problema organizacional) para sistemas multiagente, introduzido por Ishida (1998), define a eficiência da solução de um problema cooperativo de acordo com o tipo de organização entre os agentes. Entretanto, os trabalhos citados não fazem uma análise direta entre a quantidade de movimentos totais e individuais e a quantidade de caminhos ótimos encontrados. Através dessa análise, é possível entender a relação entre essas quantidades, possibilitando assim, o aumento de desempenho do sistema.

Quanto mais caminhos ótimos encontrados em um ambiente, maior o desempenho dos agentes, pois com mais caminhos disponíveis, menos colisões ocorrerão ao mesmo tempo que se assegura que os agentes percorrerão os caminhos ótimos. O presente artigo tem como objetivo responder à questão: “como a variação no número de caminhos ótimos influencia nas distâncias percorridas pelos agentes utilizando o LRTA* em ambientes estáticos?”.

Para responder à questão, adaptou-se o LRTA* para funcionar de maneira cooperativa e foi implementado um sistema multiagente. Foram realizados testes

variando a quantidade de agentes (de 1 a 10) e a quantidade de caminhos ótimos a serem encontrados (de 1 a 10). Como resultado desse trabalho é possível inferir que a partir do momento que o primeiro caminho ótimo é encontrado, os demais podem ser encontrados com um custo extra pequeno. Com isso, em ambientes onde há vários agentes que compartilham dos mesmos objetivos, quanto mais caminhos ótimos houver no ambiente, menos colisões irão ocorrer entre os agentes. Portanto, se faz vantajoso encontrar mais de um caminho ótimo nesse tipo de cenário.

Este artigo está dividido da seguinte maneira: A Seção de materiais e métodos apresenta a metodologia de pesquisa utilizada. Na Seção de resultados e conclusões, estão os resultados e discussões provenientes da pesquisa. E por fim, na Seção de conclusão, as conclusões e trabalhos futuros.

MATERIAIS E MÉTODOS

O LRTA*, proposto por Korf (1990), é um algoritmo de busca e aprendizado em tempo real de caminhos ótimos entre dois pontos distintos em ambientes onde os estados são discretizados, que utiliza uma heurística inicial pré-calculada para cada estado do ambiente. Por ser um algoritmo de aprendizado, ele tende a melhorar o valor da heurística de cada estado através da repetição de execuções, até o momento em que todos os estados que pertencem aos caminhos ótimos tenham os valores de suas heurísticas iguais ao custo real até o estado objetivo.

Os agentes presentes nesse trabalho são definidos como sendo do tipo BDI, no qual seus estados mentais são definidos por *beliefs* (crenças), *desires* (desejos) e *intentions* (intenções) (GEORGEFF et al., 1998). Cada agente tem por crenças as posições de partida, chegada, a própria posição atual e a dos obstáculos do ambiente. Eles têm por objetivo alcançar o local de chegada. Os agentes intercalam planejamento e ação por meio da execução do LRTA* para alcançar seu objetivo (intenção). Os agentes são capazes de executar movimentos de uma posição para cima, baixo, esquerda ou direita, sendo o custo de cada movimento igual a 1.

Nesse contexto, os agentes não têm conhecimento dos caminhos ótimos, e devem buscá-los através do algoritmo LRTA* (que neste trabalho utiliza a heurística Manhattan). Para o uso cooperativo do LRTA* foi realizado uma adaptação do mesmo. Essa adaptação consiste no compartilhamento da mesma matriz de valores por todos os agentes, na forma de **quadro branco**, isto é, cada movimento realizado por um agente que contribui na evolução da busca do caminho ótimo é imediatamente compartilhado com os demais, controlando-se o acesso concorrente.

Os dados a serem coletados e analisados são a distância percorrida total (quantidade de movimentos totais realizados por todos os agentes), a distância percorrida individual (a quantidade de movimentos *per capita*, sendo que ela surge da divisão entre a quantidade total de movimentos pela quantidade de agentes no ambiente), a acurácia da heurística (dada pela Eq. (1)) e o tamanho do caminho ótimo.

$$\text{Acurácia heurística} = \frac{\text{Custo estimado entre a posição inicial e objetivo}}{\text{Custo real entre posição inicial e objetivo}} \quad (1)$$

Para a análise, foi considerado um grid de tamanho 16x16. Os obstáculos foram dispostos de maneira aleatória e sua quantidade foi fixada em 35%, a qual está presente no *benchmark* proposto por Sturtevant (2012). Além disso, os estados de início e objetivo também foram definidos de maneira aleatória. O número de agentes presentes no ambiente foi elevado gradualmente, variando de 1 a 10 agentes, para cada quantidade de caminhos ótimos, sendo esses variados de 1 a 10. Para cada combinação entre as quantidades de agentes e caminhos ótimos foram realizados 100 testes, totalizando assim 10000 testes.

Para que um teste seja considerado válido e seus dados contabilizados, é necessário que os caminhos ótimos tenham tamanhos – isto é, a distância entre o local de partida e chegada – superiores a 5. Essa delimitação é necessária para evitar que caminhos muito curtos sejam levados em conta, prejudicando a análise dos dados coletados. Além disso, a acurácia da heurística (Eq. (1)) deve ser inferior a 1,00, essa condição é imposta visando evitar os casos em que os caminhos ótimos são dados pela própria heurística inicial.

Após o cenário aleatório ser gerado, utilizou-se o algoritmo de *Dijkstra* para encontrar todos os caminhos ótimos existentes no ambiente (CHEN, 2003). Essa informação é utilizada para saber quantos caminhos ótimos foram encontrados pelos agentes. Para tal, é necessária a comparação de todos os estados que fazem parte de cada caminho ótimo. Se todas as posições que fazem parte de um caminho ótimo tiverem seus valores de heurística igual ao custo até o estado objetivo, significa que aquele caminho ótimo foi encontrado.

Para o cenário ser utilizado no teste, a quantidade de caminhos ótimos encontrados previamente pelo algoritmo de *Dijkstra* deve ser superior a quantidade a ser encontrada pelos agentes usando o LRTA*. Por exemplo, se o teste demanda do encontro de 10 caminhos ótimos, o mínimo que o algoritmo de *Dijkstra* deve retornar são 10 caminhos. Caso isso não aconteça, o cenário é descartado e um novo gerado.

Para analisar e encontrar a melhor quantidade de agentes na busca pelos caminhos ótimos, é utilizado a Eficiência de Pareto (VIDAL, 2007). Nessa situação, busca-se minimizar as quantidades de movimentos totais e individuais. Além disso, outra maneira para encontrar a melhor quantidade é a utilização do limiar de 1,00% em relação ao ganho percentual dado pela Eq. (2). Nesse limiar, quando a diferença de um agente para o outro for menor do que 1,00%, a primeira quantidade de agentes é considerada a mais eficiente.

$$\text{Ganho percentual} = 100 - \frac{\text{Movimentos individuais}}{\text{Movimentos realizados por 1 agente}} \times 100[\%] \quad (2)$$

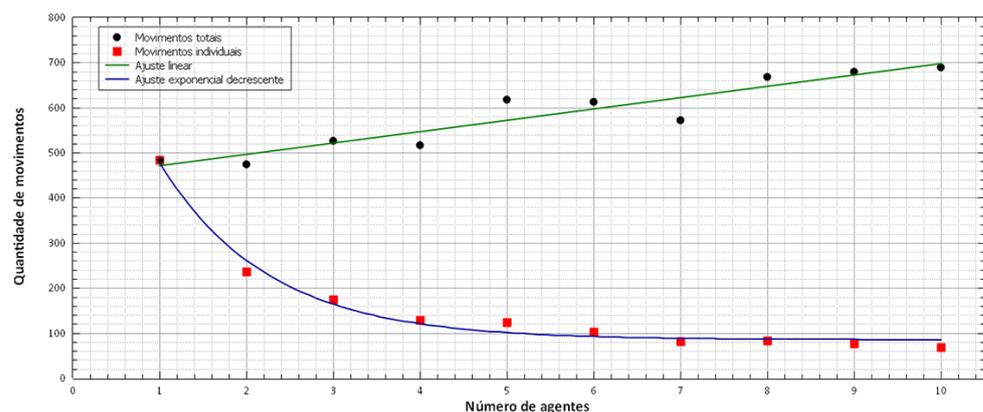
Vale ressaltar, que nos experimentos realizados, a colisão entre agentes foi desprezada, isto é, vários agentes podem ocupar o mesmo espaço ao mesmo tempo. Essa característica não tem influência no resultado, visto que o objeto a ser estudado são as distâncias percorridas pelos agentes. Em um ambiente real, basta fazer com que, no caso de possibilidade de colisão, um agente espere até que a posição a ser ocupada esteja livre (ex. com uso de um monitor/semáforo).

RESULTADOS E DISCUSSÕES

Após a coleta dos dados, foram gerados 10 gráficos, onde cada um faz referência a uma quantidade de caminhos ótimos a ser encontrada. Os gráficos apresentam a variação da quantidade de movimentos totais e individuais (*per capita*) pela variação na quantidade do número de agentes no ambiente. A Figura 1 apresenta o resultado obtido para a busca de 5 caminhos ótimos. Os pontos em preto representam os movimentos totais enquanto os quadrados vermelhos os movimentos individuais. A linha verde representa o ajuste linear realizado com os movimentos totais, e a curva azul representa o ajuste de uma exponencial decrescente com os movimentos individuais.

É possível observar que na Figura 1, as quantidades de movimentos totais e individuais se comportam como duas curvas matemáticas, sendo a primeira uma curva linear e a segunda uma exponencial decrescente. Essa característica esteve presente nos 10 gráficos gerados.

Figura 1 – Quantidade de movimentos totais e individuais pelo número de agentes para o encontro de 5 caminhos ótimos



Fonte: Autoria própria (2020).

Além disso, através do limiar de 1,00%, constatou-se que a melhor quantidade de agentes para o encontro dos caminhos ótimos foi de 5 agentes. Mesmo essa quantidade não sendo unânime (foi a melhor em 4 dos 10 cenários sendo que nos outros 6 a diferença foi inferior que 5%), ela apresentou uma boa eficiência para qualquer quantidade de caminhos ótimos, apresentando o máximo, ou próximo a este, em termos de eficiência na busca pelos caminhos ótimos.

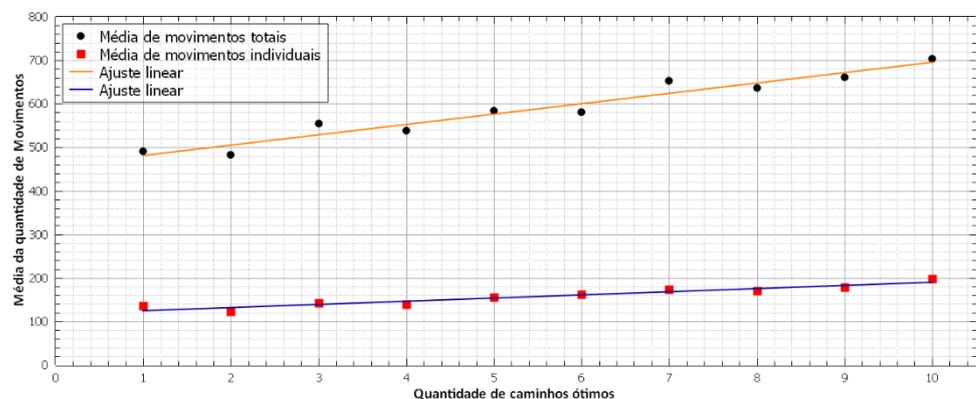
Da mesma forma, ao utilizar a Eficiência de Pareto, observa-se que ao diminuir a quantidade de movimentos totais, a quantidade individual aumenta, e vice versa. Dessa maneira, ao utilizar o Ótimo de Pareto visando a melhor minimização possível, constatou-se que o uso de 5 agentes apresentou a melhor minimização em 2 dos 10 cenários possíveis, sendo a segunda melhor em outros 3, e estando entre os 5 em outros 4 cenários. Dessa maneira, é possível afirmar que o uso de 5 agentes é o mais eficiente em termos gerais, levando em conta todos os cenários. O uso de 5 agentes como sendo o mais eficiente coincide com o definido por Ishida (1998) para agentes do tipo básico.

Além disso, ao realizar a média da quantidade de movimentos totais para cada quantidade de caminhos ótimos, observou-se que a variação de um para outro foi

pequena. Na Figura 2, os pontos pretos representam as médias dos movimentos totais, os quadrados vermelhos as médias de movimentos individuais, e as curvas laranja e azul são o ajuste dos dados citados respectivamente.

Através da Figura 2, é possível constatar que a partir do momento em que um caminho ótimo é encontrado, os demais caminhos demandam uma pequena quantidade extra para que também sejam encontrados. A curva de tendência dos movimentos totais apresenta uma inclinação levemente superior à dos movimentos individuais. A média geral dos movimentos totais, incluindo todas as possibilidades de caminhos, foi de 588 movimentos com um desvio padrão amostral de 74, enquanto que a média de movimentos individuais foi de 158 com desvio padrão amostral de 23.

Figura 2 – Média da quantidade de movimentos totais pela quantidade de caminhos ótimos encontrados



Fonte: Autoria própria (2020).

Essa característica se deve ao fato do algoritmo LRTA* utilizar a aleatoriedade para a definição do próximo estado, quando duas ou mais possibilidades de movimentação apresentam o mesmo valor de heurística. Devido a isso, o LRTA* demora mais tempo para encontrar o primeiro caminho ótimo, entretanto, uma vez encontrado, ele necessita menos esforço para o encontro dos demais.

CONCLUSÃO

Esta pesquisa teve como propósito entender como a variação na quantidade de caminhos ótimos influencia nas distâncias percorridas pelos agentes utilizando o LRTA* em ambientes estáticos. Com a análise dos dados coletados, foi possível responder à pergunta de pesquisa inicial. Ao aumentar a quantidade de caminhos ótimos, a quantidade de movimentos totais a serem realizados pelos agentes tende a aumentar como uma curva linear, enquanto que a curva de movimentos individuais também se comporta como uma curva linear, entretanto com uma inclinação muito pequena.

Com isso, conclui-se que a partir do momento em que o primeiro caminho ótimo é encontrado, os demais podem ser descobertos sem grande esforço computacional extra. Esse fato é relevante, pois, em cenários onde os caminhos ótimos são relevantes e mais de um agente está presente no ambiente, quanto mais caminhos ótimos estiverem disponíveis, menos colisões irão ocorrer,

evitando assim, que um agente tenha que esperar a sua próxima posição estar livre. Isso implica que se faz vantajoso encontrar mais de um caminho ótimo em sistemas com mais de um agente, onde eles têm de sair de um mesmo local e chegar a outro.

Além disso, observou-se que ao aumentar a quantidade de agentes na busca pelos caminhos ótimos, a quantidade de movimentos totais tende a se comportar como uma curva linear, enquanto que os movimentos individuais tende a se comportar como uma exponencial decrescente. Com isso, é possível concluir através dos testes, que a melhor quantidade de agentes para o encontro de caminhos ótimos (entre 1 e 10 caminhos) em ambiente com 35% de obstáculos aleatórios é de 5 agentes, usando como base o Ótimo de Pareto e o limiar de 1,00%.

Outro produto desse trabalho é a possibilidade do reuso da versão cooperativa do LRTA* em problemas onde o ambiente não é um *grid*, como por exemplo, situações onde a transição entre estados é dada por um grafo. Para tal, basta a adaptação do algoritmo de acordo com as características do problema (ex. utilizar uma matriz de adjacência). Por ter o algoritmo LRTA* como base, em qualquer problema onde ele é utilizado de maneira individual, através dessa adaptação, é possível utilizá-lo de maneira cooperativa.

Como trabalho futuro, pretende-se considerar o custo da comunicação entre os agentes (considerando o número de leituras/escritas na memória compartilhada). Além disso, outro trabalho relevante é considerar mais lugares de início e objetivo, fazendo com que os agentes compartilhem conhecimentos, mas tenham objetivos distintos em um mesmo cenário.

AGRADECIMENTOS

A Fundação Araucária pelo fomento fornecido em apoio a iniciação científica. Ao meu professor orientador Cesar Augusto Tacla pelas valiosas contribuições dadas durante todo o processo.

REFERÊNCIAS

CHEN, Jing-Chao . Dijkstra's shortest path algorithm — **Journal Of Formalized Mathematics**- Shanghai- mar.2003 — p. 237-247. Disponível em: <http://mizar.org/fm/2003-11/pdf11-3/graphsp.pdf>. Acesso em: 15 jul. 2020.

FELNER, Roni Stern Solomon Eyal Shimony Ariel et al. Search-Based Optimal Solvers for the Multi-Agent Pathfinding Problem: Summary and Challenges. In: TENTH INTERNATIONAL SYMPOSIUM ON COMBINATORIAL SEARCH, 10., 2017, Pittsburgh, Pennsylvania, Usa. **Proceedings [...]**. Palo Alto, California: Aaai, 2017. p. 29-37. Disponível em: <https://people.engr.tamu.edu/guni/pistar/Papers/SOCS17-MAPF.pdf>. Acesso em: 10 maio 2020.

GEORGEFF, Michael et al. The Belief-Desire-Intention Model of Agency. In: ATAL: INTERNATIONAL WORKSHOP ON AGENT THEORIES, ARCHITECTURES, AND

LANGUAGES, 5., 1998, Paris, France. **Proceedings [...]**. Berlin, Heidelberg: Springer, 1998. v. 1, p. 1-10. Disponível em: https://link.springer.com/chapter/10.1007/3-540-49057-4_1. Acesso em: 10 jan. 2020.

HÖNIG, Wolfgang et al. Persistent and Robust Execution of MAPF Schedules in Warehouses. **IEEE Robotics And Automation Letters**. LOCAL, p. 1125-1131. abr. 2019. Disponível em: <https://ieeexplore.ieee.org/document/8620328>. Acesso em: 10 maio 2020.

KORF, Richard E. Real-time heuristic search. **Artificial intelligence**, v. 42, n. 2-3, p. 189-211, 1990. Disponível em: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.137.1955&rep=rep1&type=pdf>. Acesso em: 10 de maio de 2020.

MA, Hang, et al. — Overview: Generalizations of multi-agent path finding to real-world scenarios — **arXiv preprint arXiv:1702.05515**, 2017. Disponível em: <https://arxiv.org/abs/1702.05515>. Acesso em: 15 de janeiro de 2020.

SIGURDSON, Devon. **Automatic Algorithm Selection in Videogame Pathfinding**. 2018. 59 f. Dissertação (Mestrado) - Curso de Master Of Science, Department Of Computing Science, University Of Alberta, Alberta, Canadá, 2018. Disponível em: <https://era.library.ualberta.ca/items/70dc00f8-d6eb-44e4-ae21-4145b712a9ae/view/852e5935-ef5e-49ee-9ce8-23fb4426f3f7/thesis.pdf>. Acesso em: 12 fev. 2020.

STANDLEY, Trevor. Finding Optimal Solutions to Cooperative Pathfinding Problems. In: TWENTY-FOURTH AAAI CONFERENCE ON ARTIFICIAL INTELLIGENCE (AAAI-10), 24., 2010, Atlanta, Georgia, Eua. **Proceedings [...]**. Atlanta, Georgia, Eua: Aaai Press, 2010. p. 173-178. Disponível em: <https://www.aaai.org/ocs/index.php/AAAI/AAAI10/paper/view/1926/1950>. Acesso em: 10 mar. 2020.

STERN, Roni. Multi-Agent Path Finding – An Overview. **Artificial Intelligence**, Cham, v. 11866, p. 96-115, 14 out. 2019. Disponível em: https://doi.org/10.1007/978-3-030-33274-7_6. Acesso em: 10 fev. 2020.

STERN, Roni et al. Multi-Agent Pathfinding: Definitions, Variants, and Benchmarks. In: TWELFTH INTERNATIONAL SYMPOSIUM ON COMBINATORIAL SEARCH, 12., 2019, Napa. **Proceedings [...]**. Palo Alto, California: Aaai Press, 2019. p. 151-158. Disponível em: <https://aaai.org/ocs/index.php/SOCS/SOCS19/paper/viewFile/18341/17457>. Acesso em: 01 fev. 2020.

STURTEVANT, Nathan R.. Benchmarks for Grid-Based Pathfinding. **IEEE Transactions On Computational Intelligence And Ai In Games**. p. 144-148. jun. 2012. Disponível em: <https://ieeexplore.ieee.org/document/6194296>. Acesso em: 10 fev. 2020.

VIDAL, José M. **Fundamentals of Multiagent Systems: Using NetLogo Models**. 2010. Disponível em: <http://jmvidal.cse.sc.edu/papers/mas.pdf>. Acesso em: 01 fev. 2020.

ZAFAR, Kashif; BAIG, Abdul Rauf. Optimization of route planning and exploration using multi agent system. **Multimedia Tools And Applications**. p. 245-265. jan. 2012. Disponível em: <https://doi.org/10.1007/s11042-010-0585-0>. Acesso em: 01 fev. 2020.