

MONTE CARLO TREE SEARCH: A REVIEW OF DRAWBACKS, ADVANTAGES AND LIMITATIONS IN COMPLEX MULTIPLAYER GAMES

JOÃO LUÍS ALMEIDA SANTOS¹, ANDREI CAMILOTTO², DJONATAN BONELLI³,
EDUARDO FIORENTIN⁴, FELIPE GRANDO⁵

1 Introdução

Monte Carlo Tree Search (MCTS) é uma família de algoritmos de busca que constrói uma árvore de decisões por meio de quatro etapas: seleção, expansão, simulação e retropropagação. Em vez de exigir uma função de avaliação completa para cada estado, o método estima a qualidade das ações a partir de numerosas simulações, equilibrando a exploração de alternativas pouco visitadas e o aproveitamento de ações. Essa característica contribuiu para resultados expressivos em jogos como Go, Xadrez e Shogi, sobretudo em ambientes para dois jogadores e com informação perfeita (BROWNE et al., 2012).

Entretanto, jogos digitais e de mesa contemporâneos apresentam condições mais complexas: vários adversários, informação oculta, aleatoriedade, espaços de ações amplos e decisões em tempo real. Nessas situações, uma simulação adicional nem sempre produz uma decisão melhor. O aumento do número de jogadores amplia a árvore de busca e torna difícil modelar as respostas dos oponentes. A informação imperfeita pode gerar fusão de estratégias quando estados ocultos são tratados de modo inadequado, enquanto a pressão temporal reduz o orçamento computacional disponível. Apesar da crescente aplicação da MCTS nesses cenários, a literatura permanece fragmentada e concentrada em jogos clássicos.

2 Objetivos

Este trabalho teve como objetivo geral identificar e organizar limitações recorrentes da

¹Acadêmico de Ciência da Computação - UFFS, Campus Chapecó - jluis.kaldwin@gmail.com

²Acadêmico de Ciência da Computação - UFFS, Campus Chapecó - andrei.camilotto@gmail.com

³Acadêmico de Ciência da Computação - UFFS, Campus Chapecó - djonatan0604@gmail.com

⁴Acadêmico de Ciência da Computação - UFFS, Campus Chapecó - eduardofiorentin336@gmail.com

⁵Doutor em Computação - UFFS, Campus Chapecó, **Orientador** - felipegrando.uffs@gmail.com

⁶Grupo de Pesquisa: Inovação e Desenvolvimento Tecnológico - IDT

MCTS em jogos multijogador, digitais e de mesa, especialmente em ambientes com informação imperfeita, estocasticidade e restrições de tempo.

Como objetivos específicos, buscou-se reunir as estratégias para mitigar essas limitações e identificar lacunas de pesquisa capazes de orientar estudos futuros e favorecer avaliações mais comparáveis e reproduzíveis.

3 Metodologia

Foi realizada uma revisão bibliográfica de estudos publicados entre 2013 e 2025, com buscas nas bases IEEE Xplore, HAL Science Ouverte e Google Scholar. As estratégias de busca combinaram os termos "Monte Carlo Tree Search" e "MCTS" com expressões relacionadas a jogos digitais, jogos de tabuleiro e jogos multijogador. A triagem considerou trabalhos cujo título ou resumo abordasse a MCTS, uma variante direta ou um método híbrido aplicado a jogos competitivos ou cooperativos. Foram excluídos estudos fora do escopo, documentos sem acesso ao texto completo e trabalhos cujo escopo não era compatível com os objetivos da revisão.

As buscas recuperaram 24 registros, dos quais dois eram duplicados entre consultas, resultando em 22 trabalhos únicos potencialmente relevantes (17 em inglês e cinco em francês). Após a triagem, 18 estudos foram selecionados para análise integral e quatro foram excluídos. O corpus final reuniu 13 estudos da IEEE Xplore, três da HAL e dois localizados pelo Google Scholar, enquanto, entre os selecionados, 15 textos estavam em inglês e três em francês. Os trabalhos foram classificados quanto ao tipo de jogo, algoritmo empregado, restrições do ambiente, resultados reportados e estratégias de mitigação. A análise temática foi organizada em três categorias estruturais de limitação, limites de desempenho, pontos cegos táticos e compromissos no modelamento de oponentes, e em dois amplificadores dependentes do domínio, informação imperfeita e decisões em tempo real.

4 Resultados e Discussão

Os estudos analisados indicam que a MCTS apresenta desempenho mais consistente em jogos com estados bem definidos, fator de ramificação moderado e orçamento computacional suficiente para realizar um número elevado de simulações. Entre os 18 trabalhos selecionados, oito abordaram jogos digitais, seis investigaram jogos de tabuleiro ou

de mesa e os demais analisaram jogos de cartas, ambientes de jogo geral ou aplicações correlatas. Algoritmos baseados em MCTS foram empregados em 14 estudos, frequentemente combinados com redes neurais, abstrações do espaço de ações, políticas de simulação e técnicas de ajuste de parâmetros.

A primeira limitação identificada refere-se ao desempenho da busca. Embora o aumento do número de simulações normalmente melhore a qualidade das decisões, os ganhos marginais tendem a diminuir à medida que novas simulações passam a revisitar trajetórias já suficientemente exploradas. Resultados obtidos em Go, jogos de estratégia em tempo real e jogos de mesa mostram que dobrar o orçamento computacional pode produzir benefícios reduzidos ou inexistentes após determinado ponto. Além disso, estudos sobre profundidade de habilidade demonstram que esse limite depende tanto da complexidade do jogo quanto da configuração do agente. Como estratégias de mitigação destacam-se a abstração do espaço de ações, a simplificação das simulações e o ajuste automático de políticas, constantes de exploração e estratégias de rollout por meio do N-Tuple Bandit Evolutionary Algorithm (NTBEA) (GOODMAN; PEREZ-LIEBANA; LUCAS, 2024).

A segunda limitação corresponde aos pontos cegos do raciocínio tático. Como a MCTS estima o valor médio das continuidades amostradas, o algoritmo pode falhar diante de posições que exigem reconhecer sequências táticas específicas, ameaças de longo prazo ou configurações pouco frequentes. Em Go, situações como escadas e o semeai ilustram cenários nos quais uma estrutura tática evidente para jogadores experientes pode não ser identificada pela busca.

A terceira limitação envolve a modelagem de oponentes. Em jogos com três ou mais participantes, o processo de busca deve representar não apenas as decisões do jogador na raiz da árvore, mas também as possíveis respostas de cada adversário. Modelos que mantêm estruturas independentes para cada oponente tendem a representar melhor o comportamento estratégico, embora aumentem significativamente o custo computacional. Em contrapartida, abordagens simplificadas, como o Paranoid Search e políticas generalizadas, reduzem esse custo, mas podem deixar de representar comportamentos relevantes. A literatura sugere que abordagens baseadas em foco seletivo, generalização das respostas dos adversários e decomposição da árvore representam alternativas promissoras, embora ainda pouco avaliadas em jogos com grande número de participantes (BAIER; KAISERS, 2020).

A informação imperfeita intensifica essas limitações. Em jogos de cartas, Pokémon e outros ambientes com estados ocultos, a determinização, que consiste em assumir uma configuração possível das informações desconhecidas e realizar a busca como se ela fosse verdadeira, pode provocar a fusão de estratégias incompatíveis. A *Information Set MCTS*, uma variação do algoritmo de busca em árvore de Monte Carlo projetada para lidar com incertezas, reduz esse problema ao agrupar estados indistinguíveis para o jogador, preservando apenas as informações efetivamente disponíveis no momento da decisão (COWLING; POWLEY; WHITEHOUSE, 2012). Ainda assim, a aleatoriedade inerente ao ambiente e a necessidade de inferir o comportamento dos adversários continuam limitando a confiabilidade das estimativas produzidas.

Em ambientes de tempo real, como jogos de estratégia, MOBAs e jogos de tiro em primeira pessoa, as restrições temporais tornam-se um fator crítico. A MCTS precisa selecionar ações em intervalos muito curtos enquanto administra espaços de ações combinatórios, múltiplas unidades e observações parciais. Nesse contexto, abstrações hierárquicas, macroações, poda de ações e políticas obtidas por aprendizado supervisionado ou por aprendizado por reforço aparecem como estratégias recorrentes (ONTAÑÓN, 2013). Em determinadas situações, métodos alternativos podem apresentar melhor desempenho. O Rolling Horizon Evolutionary Algorithm (RHEA), por exemplo, evolui sequências curtas de ações e realiza replanejamento contínuo, mostrando-se particularmente adequado para jogos cooperativos e ambientes altamente estocásticos, nos quais a árvore de busca se modifica rapidamente (SFIKAS; LIAPIS, 2022).

Também foram identificadas aplicações da MCTS menos dependentes de decisões em tempo real, como balanceamento automático, playtesting e apoio ao projeto de jogos. Nesses cenários, o tempo de processamento deixa de ser uma restrição crítica, permitindo explorar extensivamente diferentes configurações, identificar desequilíbrios e avaliar alternativas de projeto. Embora a maior parte dos estudos reporte resultados favoráveis às abordagens propostas, alguns trabalhos observaram desempenho inferior da MCTS em comparação com técnicas concorrentes, como nos jogos Kingdomino e Pandemic.

5 Conclusão

A revisão também identificou cinco oportunidades relevantes para pesquisas futuras:

(i) adoção e padronização de benchmarks compartilhados para jogos multijogador com informação imperfeita; (ii) avaliação sistemática de técnicas de modelagem de oponentes em jogos com maior número de participantes; (iii) investigação da relação entre a complexidade percebida por jogadores humanos e a profundidade efetiva da busca; (iv) estudo de séries competitivas melhor de três e melhor de cinco, considerando histórico de escolhas e banimentos; e (v) ampliação das aplicações da MCTS em balanceamento automático, playtesting e geração procedural de conteúdo.

Referências Bibliográficas

BAIER, H.; KAISERS, M. **Guiding multiplayer mcts by focusing on yourself**. In: IEEE Conference on Games (CoG). [S.l.: s.n.], 2020. p. 550–557.

BROWNE, C. et al. **A survey of monte carlo tree search methods**. IEEE Transactions on Computational Intelligence and AI in Games, v. 4, n. 1, p. 1–43, 2012.

COWLING, P. I.; POWLEY, E. J.; WHITEHOUSE, D. **Information set monte carlo tree search**. IEEE Transactions on Computational Intelligence and AI in Games, v. 4, n. 2, p. 120–143, 2012.

GOODMAN, J.; PEREZ-LIEBANA, D.; LUCAS, S. **Skill depth in tabletop board games**. In: 2024 IEEE Conference on Games (CoG). [S.l.: s.n.], 2024. p. 1–8.

ONTAÑÓN, S. **The combinatorial multi-armed bandit problem and its application to real-time strategy games**. In: Proceedings of the Ninth AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment (AIIDE). [S.l.: s.n.], 2013. p. 58–64.

SFIKAS, K.; LIAPIS, A. **Playing against the board: Rolling horizon evolutionary algorithms against pandemic**. IEEE Transactions on Games, v. 14, n. 3, p. 339–349, set. 2022.

Palavras-chave: Monte Carlo Tree Search, Inteligência artificial, Jogos multijogador, Informação imperfeita, Revisão sistemática da literatura

Nº de Registro no sistema Prisma: PES-2025-0020.

Financiamento

