
MÉTODOS EVOLUTIVOS DE INTELIGÊNCIA ARTIFICIAL PARA JOGOS

EVOLUTIONARY ARTIFICIAL INTELLIGENCE METHODS FOR GAMES

Wellington Endo¹
Simone Sawasaki Tanaka²

RESUMO

Este trabalho apresenta uma abordagem sobre uma pesquisa de construção de redes neurais com uma IA (Inteligência Artificial), aplicada em jogos. O objetivo é explicar como um personagem pode se comportar com uma IA implementada no sistema do jogo. Existem métodos que podem ser utilizados para evoluir uma IA em jogos, dentre eles podemos citar o HyperNEAT e também existem outros métodos de ambientes de testes. Pesquisas anteriores feitas através de jogos antigos, demonstravam que haviam limitadas ações de espaços. Com o tempo decorrido, os jogos modernos disponibilizam as escolhas das diversas e vastas ações, isso ocorre pela capacidade do jogador selecionar várias ações entre um espaço combinatório de centenas de possibilidades, concedendo assim conjuntos ricos de desafios. Esses desafios ainda não foram superados, então pesquisas anteriores sugerem que é mais propenso a ter uma abordagem específica ao tentar construir um modelo de IA de uso geral. O algoritmo imitador com *clustering*, aparenta ter uma boa solução para jogos que não forem complexos. Já o *HyperNEAT* aparenta ser melhor do que os demais, devido a probabilidade de solucionar problemas complexos.

Palavras-chave: inteligência artificial; jogos; algoritmos evolutivos; redes neurais.

ABSTRACT

This work presents an approach on a research on the construction of neural networks with an AI (Artificial Intelligence), applied in games. The aim is to explain how a character can behave with an AI implemented in the game system. There are methods that can be used to evolve an AI in games, among them we can mention, HyperNEAT, there are also test environments. Previous research done through old games, showed that there were limited space actions, with the elapsed time, modern games have vast and diverse action choices, this is due to the player's ability to select several actions among a combinatorial space of hundreds of possibilities, thus granting rich sets of challenges. These challenges have not yet been overcome, so past research suggests

¹ Graduando do Curso de Ciência da Computação, Centro Universitário Filadélfia - UniFil. Departamento de Computação. Londrina - Paraná - Brasil. 86020-000 - wellington.endo@edu.unifil.br

² Professor do Centro Universitário Filadélfia - Unifil. Departamento de Computação Londrina - Paraná - Brasil. 86020-000 - simone.tanaka@unifil.br

that you are more likely to take a specific approach when trying to build a general-purpose AI model. The imitation algorithm with clustering seems to have a good solution for games that are not complex. HyperNEAT, however, appears to be better than the others, due to the probability of solving complex problems.

Keywords: artificial intelligence; games; evolutionary algorithms; neural networks.

1 INTRODUÇÃO

Devido a exploração sobre o tema IA (IA, da sigla do termo inglês, *Artificial Intelligent*), novas áreas surgiram e dentre elas, surgiu o campo de estudos sobre jogos. O trabalho apresenta alguns métodos que são utilizados para aprimorar algum aspecto do jogo com uma IA.

Um dos primeiros jogos a ter um teste com a implementação de IA, foi o jogo da Dama, pesquisado pelo cientista da computação Arthur Samuel (HAUSKNECHT *et al.*, 2014).

Dentre os algoritmos que foram abordados neste trabalho, estão o *HyperNEAT* que demonstrou um desempenho melhor do que outros testados (HAUSKNECHT *et al.*, 2014). Os outros algoritmos testados retratados acima eram o *NEAT* (*NEAT*, da sigla do termo inglês *Neuroevolution of augmenting topologies*), *CNE* (*CNE*, da sigla do termo inglês *Conventional Neuroevolution*) e *CMA-ES* (*CMA-ES*, da sigla do termo inglês *Covariance matrix adaptation evolution strategy*).

Neste trabalho foram estudados os diversos métodos de IA para evolução dos personagens de jogos e efetuado uma comparação da mesma.

O objetivo desta pesquisa é analisar os métodos evolutivos utilizados em jogos e verificar qual se adapta melhor a um determinado contexto.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, mostraram uma pesquisa feita em torno do tema referente a este trabalho. Um dos objetivos é mostrar as comparações entre métodos evolutivos e exemplificar sobre qual método se encaixa melhor no contexto, assim exemplificando a Inteligência Artificial, o que ela traz de melhor em jogos e o principal, os métodos evolutivos.

2.1 INTELIGÊNCIA ARTIFICIAL (IA)

A IA é um campo de estudo de Ciência e de Engenharia, com o objetivo científico de compreender os princípios que permitem o comportamento inteligente em humanos, animais e agentes inteligentes (TECUCI, 2012).

Através dos estudos antecedentes daquelas pesquisas, surgiram novas áreas de estudos e dentre elas, o estudo de IA em jogos.

A IA está presente desde os primeiros jogos e o primeiro a fazer o experimento, foi o cientista da computação Arthur Samuel que desenvolveu um programa de jogo de damas que era treinado jogando contra ele próprio, ou jogando com outro jogador (TECUCI, 2012).

2.2 INTELIGÊNCIA ARTIFICIAL EM JOGOS

A inteligência artificial em jogos, possui o objetivo de desenvolver oponentes inteligentes ou agentes, no cenário "brains vs. brains" ("cérebros vs. cérebros) e não popularmente a situação encontrada "brains vs. brawn" ("cérebros vs. músculo") em jogos, para poder competir com o jogador (BRIDGER; GROSKOPF, 2000). De acordo com Bridger e Groskopf (2000), o motivo de usar métodos de IA em jogos, é devido aos jogos criarem um único elemento para programas, a incertezas.

Desde que surgiu a IA, o desenvolvimento em jogos sempre foi uma área de estudo da IA. Uma das pesquisas realizadas em jogos, foi do cientista da computação Arthur Samuel, ele desenvolveu um programa de jogo de damas que era treinado jogando contra ele próprio, ou jogando com outro jogador. A pesquisa dele resultou em que a aprendizagem era significativa e mensurável, podendo resultar em apenas na aprendizagem mecânica (TECUCI, 2012).

Segundo García Sánchez (2019), os jogos clássicos, como Xadrez e Dama, não foram os únicos que beneficiaram para os avanços das pesquisas feitas em torno de jogos, portanto os jogos modernos vem sendo um campo de estudos para testar novas técnicas e métodos, por exemplo, o jogo Starcraft.

2.3 ALGORITMOS EVOLUTIVOS

Estudos recentes, mostram que estão testando métodos de IA em jogos da atualidade, devido a vasta incertezas e complexidade. Porém, a complexidade é um fator relevante nos estudos dos algoritmos, pois quanto mais complexo maior é a dificuldade da pesquisa é aprofundado. Neste trabalho, apresenta algumas técnicas de IA implementadas em jogos e compararemos para ver qual se encaixa melhor no contexto. Nas seguintes subseções mostraremos os métodos estudados.

2.3.1 NEAT (*Neuroevolution Of Augmenting Topologies*)

A diferença entre o NEAT (NEAT, do termo inglês *Neuroevolution Of Augmenting Topologies*) e a CNE é que o mesmo também desenvolve a topologia da rede (HAUSKNECHT *et al.*, 2014). As duas técnicas do algoritmo genético, a mutação e o crossover, são usados para criar os descendentes, somente a especiação que é semelhante ao NEAT, ela é usada para manter a diversidade da população (HAUSKNECHT *et al.*, 2014).

Segundo Hausknecht *et al.*, o Stanley Kenneth O. Miikkulainen afirma que o método NEAT é um método evolutivo que tem como base desenvolver a topologia e os pesos da ANN.

O NEAT tenta equilibrar as soluções evoluídas e sua diversidade, adequando-os (HAUSKNECHT *et al.*, 2014). Dentre outros métodos, o NEAT supera os demais métodos de neuroevolução, e no qual ele é da classe de Algoritmos Genéticos (GA, do termo inglês *Genetic Algorithm*) que foi originalmente projetado para funcionar offline (STANLEY; BRYANT; MIIKKULAINEN, 2005).

Um dos jogos que foram testado o NEAT foi o jogo do Pac-Man, esta pesquisa foi feita pelos pesquisadores Witikamp, Barone e Hingston (2008). A rede neural usada para representar os fantasmas, foi o *feed-foward* que evoluiu por meio do algoritmo do NEAT. Contudo, utilizaram a rede neural com a ideia de uma estratégia individual com os fantasmas que evoluíram executando uma sequência de jogos simulados entre a progressão do jogo real, em base na pressão de seleção evolutiva

que recompensa um fantasma de forma individual com base no desempenho da equipe. Então, utilizaram o *NEAT* para treinar as estratégias dos fantasmas.

2.3.2 HyperNeat

O *HyperNeat* é uma extensão do algoritmo *NEAT*. O *HyperNeat* se difere dos outros métodos, como o *NEAT* e *CMA-ES* devido a codificação direta desse método de não evoluir a sua própria rede neural, já as outras evoluem a suas próprias redes neurais (HAUSKNECHT *et al.*, 2014).

Segundo Hausknecht *et al.* (2014), a *CPPN* (*CPPN*, da sigla do termo inglês *Compositional Pattern Producing Network*) é geograficamente ciente, pois calcula os pesos da *ANN* atribuídos. A *CPPN* é uma função de atribuir pesos na *ANN* para produzir uma solução do problema.

Todo o jogo de RoboCup-2D dispõe dois times contra o outro em um jogo de futebol em um campo de futebol virtual 2D (GONZÁLEZ *et al.*, 2017). O jogo é controlado por agentes e contém mecânicas das mesmas, assim, ele é comunicado através de um servidor host (GONZÁLEZ *et al.*, 2017).

O Soccer Server é um sistema que concede aos agentes autônomos compostos por programas escritos em várias linguagens jogarem uma partida de futebol entre si. Através do servidor soccerserver, ele concede um campo virtual e simula todas as mobilidades de uma bola e dos jogadores. Assim, qualquer usuário pode controlar as mobilidades de um jogador (CHEN *et al.*, 2003).

2.3.3 CMA-ES (Covariance Matrix Adaptation Evolution Strategy)

A *CMA-ES* é um método que tem uma topologia fixa para evoluir uma rede. O *CMA-ES* é usado para desenvolver os pesos, ao invés de crossover e mutação (HAUSKNECHT *et al.*, 2014).

Na pesquisa do Togelius *et al.* (2010), utilizou o *CMA-ES* para funções de valores, onde era usado como um método de otimização evolucionária padrão.

2.3.4 Imitador

Segundo (ZHOU; LI, 2020), o imitador de IA “é uma rede neural que imita as decisões do programa de IA.”. Para Torabi, Warnell e Stone (2019), a aprendizagem por imitação (IL, da sigla do termo inglês: *Imitation Learning*): É o processo pelo qual um agente tenta aprender como executar alguma tarefa utilizando as informações criadas por outro agente, comumente mais experiente, atuando a mesma tarefa (TORABI; WARNELL; STONE, 2019).

Na pesquisa de Zhou e Li (2020), ele pesquisou sobre o aprendizado por imitação com uma rede neural para agrupar as IAs em duas categorias de acordo com a sua imitabilidade. O termo imitabilidade é referindo-se a dificuldade de imitação. Utilizou também em sua pesquisa, o método de clonagem de comportamento, pelo simples fator, para explorar personagens do estilo do jogo dos bots, e os escolhidos não são todos de níveis especialistas (ZHOU; LI, 2020).

3 CONCLUSÃO

Ambos métodos estudados em vários contextos, mostraram que podiam evoluir algum aspecto do jogo, o HyperNEAT demonstrou que poderia desenvolver agentes que conseguiram uma defesa melhor, o NEAT mostrou que podiam evoluir um agente que pudesse derrotar bases em jogos de RTS e conseguir fazer com que um personagem consiga aprender algumas estratégias. O CMA-ES exibiu que não foi muito bem, pois somente aperfeiçoou alguns aspectos do jogo, o Imitador demonstrou que é possível clonar alguns comportamentos de jogos, porém pequenas, pois ela tende escolher regiões/direções. Sobre a falta de métodos intuitivos que muitos não disponibilizam os algoritmos, alguns possuíam e outros não continham. Na pesquisa de Zhou e Li (2020), ele identifico que as árvores podem ser úteis para jogos para encontrar soluções ideais, porém também podem virar uma árvore desequilibrada.

Para o trabalho futuro, pode-se pesquisar outros métodos e técnicas para descrever o que eles trazem de bom para a pesquisa na área de jogos.

REFERÊNCIAS

- BRIDGER, B. C.; GROSKOPF, C. S. Fundamentals of artificial intelligence in game development. *In: Proceedings of the 38th Annual on Southeast Regional Conference*. New York, NY, USA: Association for Computing Machinery, 2000. (ACM-SE 38), p. 51-55. Disponível em: <https://doi.org/10.1145/1127716.1127727>.
- CHEN, M. *et al.* **Users Manual: RoboCup Soccer Server - for Soccer Server Version 7.07 and Later**. [S.l.], 2003. 47
- GARCÍA-SÁNCHEZ, P. Georgios n. yannakakis and julian togelius: Artificial intelligence and games Genetic Programming and Evolvable Machines, **Kluwer Academic Publishers**, USA, v. 20, n. 1, p. 143–145, mar. 2019. Disponível em: <https://doi.org/10.1007/s10710-018-9337-0>.
- GONZÁLEZ, A. N. V. *et al.* Exploring the virtuality continuum for complex rule-set education in the context of soccer rule comprehension. **Multimodal Technologies and Interaction, Multidisciplinary Digital Publishing Institute**, v. 1, n. 4, p. 30, 2017.
- Hausknecht, M. *et al.* A neuroevolution approach to general atari game playing. **IEEE Transactions on Computational Intelligence and AI in Games**, v. 6, n. 4, p. 355-366, 2014.
- STANLEY, K. O.; BRYANT, B. D.; MIIKKULAINEN, R. Evolving neural network agent in the nero video game. **Proceedings of the IEEE**, Citeseer, p. 182-189, 2005.
- STANLEY, K. O. MIIKKULAINEN, R. Evolving neural networks through augmenting topologies. **Evolutionary Computation**, v. 10, n. 2, p. 99–127, 2002. Disponível em: <https://doi.org/10.1162/106365602320169811>.
- TECUCI, G. Artificial intelligence. **WIREs Computational Statistics**, v. 4, n. 2, p. 168–180, 2012. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/wics.200>.
- TOGELIUS, J. *et al.* Search-based procedural content generation. *In: CHIO, C. D. et al. (Ed.). Applications of Evolutionary Computation*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 141–150.
- TORABI, F.; WARNELL, G.; STONE, P. Recent advances in imitation learning from observation. CoRR, abs/1905.13566, 2019. Disponível em: <http://arxiv.org/abs/1905.13566>.
- WITTKAMP, M.; BARONE, L.; HINGSTON, P. Using neat for continuous adaptation and teamwork formation in pacman. *In: IEEE SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE AND GAMES*, 2008, Australia. **Anais [...]**. Australia: IEEE , 2008. p. 234–242.

ZHANG, L. *et al.* 1gbdt, Ir deep learning for turn-based strategy game ai. *In: IEEE Conference on Games (CoG), London, 2019. Anais [...]. London: IEEE, 2019. p. 1-8.*

ZHOU, Y.; LI, W. Discovering of game ais' characters using a neural network based aiimitator for ai clustering. *In: IEEE CONFERENCE ON GAMES (CoG), 2020, Japan. Anais [...]. Japan: IEEE, 2020.p. 198–205.*