

DESENVOLVIMENTO DIRIGIDO A MODELOS DE SIMULAÇÕES COM AGENTES: AVALIAÇÃO DE BIBLIOTECA DE APRENDIZAGEM POR REFORÇO¹

Eloísa Bazzanella², Fernando dos Santos³.

¹ Vinculado ao projeto “Desenvolvimento Dirigido a Modelos de Simulações com Agentes”

² Acadêmica do Curso de Engenharia de Software – CEAVI – Bolsista PIPES/UDESC

³ Orientador, Departamento de Engenharia de Software – CEAVI – fernando.santos@udesc.br

Agentes são sistemas inteligentes, autônomos em sua tomada de decisão e aptos a interagir com outros agentes. As simulações baseadas em agentes fazem uso de agentes simulados para reproduzir e investigar fenômenos. Para o desenvolvimento de simulações com agentes, podem ser utilizadas plataformas de simulação que fornecem recursos específicos a agentes, simplificando o desenvolvimento. Vale destacar ainda que os agentes podem incorporar técnicas de inteligência artificial para aperfeiçoar a tomada de decisão, bem como, seus comportamentos. Uma dessas técnicas é a aprendizagem por reforço e um dos métodos de aprendizagem por reforço é o Q-Learning, um algoritmo que possibilita ao agente determinar, de maneira autônoma e interativa, uma política comportamental.

Recentemente, Kons (2019) desenvolveu uma extensão para o uso da aprendizagem por reforço Q-Learning na plataforma de desenvolvimento de simulações NetLogo. A extensão serve para auxiliar na criação de agentes inteligentes, permitindo que o desenvolvedor não precise implementar o algoritmo Q-Learning manualmente. No estágio atual, o presente projeto concentrou-se em validar as melhorias proporcionadas pela extensão para o desenvolvimento de simulações baseadas em agentes inteligentes.

Para a validação, foram utilizadas quatro simulações. Uma delas é a Simulação de Controle Adaptativo de Tráfego (ATSC), que diz respeito ao desenvolvimento de semáforos inteligentes que melhoram o tráfego de veículos. A simulação adotou a modelagem do problema descrito no artigo de Oliveira e Bazzan (2009). O objetivo da simulação é aprender qual plano semaforico se ajusta melhor às condições de tráfego existentes, diminuindo o número de veículos parados.

Outra simulação utilizada é a Cliff Walking, cujo ambiente é uma grade de células, onde um subconjunto de células representa um penhasco. O propósito do agente é sair da célula inicial e alcançar a célula objetivo, fazendo o menor trajeto possível sem cair no penhasco. A terceira simulação é a Maze, que segue o mesmo princípio de sair da célula inicial e alcançar a célula final. A diferença é que o ambiente representa uma ilha envolta por um lago, e o objetivo é realizar o menor trajeto possível sem cair no lago.

A quarta simulação é a Intelligent Agents, que considera três tipos de agentes, o Standard (Rule M), o Evolutionary Computing (EC) e o Q-Learning. Durante a simulação os agentes são divididos em dois coletivos, que são identificados como "Grupo A" e "Grupo B", e cada coletivo possui apenas um tipo de agente. É simulado um conflito entre os dois grupos, onde os agentes que estão no mesmo grupo são amigos e os agentes do outro grupo são inimigos. O objetivo dos agentes é o acúmulo de riqueza na forma de açúcar. Os agentes acumulam riqueza ao coletar açúcar nas células da grade e gastam açúcar com base em seu metabolismo individual.

Para avaliar as simulações, foram utilizadas duas versões de cada simulação, uma implementada usando a extensão Q-Learning, e outra que implementa o aprendizado Q-Learning manualmente. Estas versões das simulações foram submetidas às regras de contagem de quantidade de linhas de código (LoCs) como uma maneira de mensurar o tamanho do sistema e consequentemente a simplicidade para desenvolver simulações.

A avaliação das linhas de código mostrou que o uso da extensão levou a um aumento de 2,10% no tamanho do código fonte da simulação Maze. Em contrapartida, houve uma redução de 13,54% no código fonte na simulação Cliff Walking ao utilizar a extensão, redução de 42.94% na simulação ATSC ao utilizar a extensão, e uma redução de 10.13% na simulação Intelligent Agents ao utilizar a extensão. Dessa maneira, é possível afirmar que ao utilizar a extensão Q-Learning, há uma redução significativa no número de linhas de código.

Outra avaliação realizada diz respeito a complexidade cognitiva. A complexidade cognitiva, segundo Báron *et al* (2020), visa mensurar a compreensibilidade do código, e é uma métrica que vem ganhando destaque na comunidade de Engenharia de Software.

Esta avaliação demonstrou que o uso da extensão reduziu a complexidade cognitiva em todas as simulações. A simulação Cliff Walking teve uma redução de 20%, a simulação Maze teve uma redução de 15%, a simulação ATSC apresentou redução de 36,84% e, por fim, a simulação Intelligent Agents teve redução de 3,63%. Dessa forma, é possível perceber que ao utilizar a extensão Q-Learning, há uma redução considerável na complexidade de compreensão de código.

Através da coleta desses dados, foi elaborado um artigo que foi submetido e aceito no WESAAC (Workshop-School on Agents, Environments, and Applications)(BAZZANELLA, SANTOS, 2021).

Como sugestão para aprimoramentos futuros, é possível mencionar uma análise quantitativa referente ao tempo de execução das simulações e uma análise de tempo de desenvolvimento das simulações, com programadores.

Palavras-chave: Simulações baseadas em Agentes, Aprendizagem por Reforço, Q-Learning.

Referências

- BÁRON, Marvin Munoz; WYRICH, Marvin; WAGNER, Stefan. **An empirical validation of cognitive complexity as a measure of source code understandability.** 2020
- BAZZANELLA, Eloísa; SANTOS, Fernando. **Does a Q-Learning NetLogo extension simplify the development of agent-based simulations?** In *Proceedings of the 15th Workshop-School on Agents, Environments, and Applications (WESAAC)*, to appear, Rio de Janeiro, RJ, 2021.
- BREARCLIFFE, Dale K; CROOKS, Andrew. **Overview, design concepts, and details for the model creating intelligent agents.** 2020.
- KONS, Kevin. **Biblioteca Q-Learning para desenvolvimento de simulações com agentes na plataforma NetLogo.** Trabalho de Conclusão de Curso. Universidade do Estado de Santa Catarina (UDESC), 2019.
- OLIVEIRA, Denise de; BAZZAN, Ana L. C; **Multiagent learning on traffic lights control: effects of using shared information.** IGI Global. 307–321, 2009.