

Universidade de Pernambuco

Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Tese de Doutorado

Área: Inteligência Computacional

Título: Inteligência de enxames com aprendizado de máquina por reforço para resolução de problemas complexos

Orientador – Carmelo José Albanez Bastos Filho (carmelofilho@upe.br)

Co-orientador – Hugo Valadares Siqueira hugosiqueira@utfpr.edu.br UTFPR

Descrição

Técnicas de inteligência computacional têm obtido destaque na literatura na última década devido ao seu poder de busca baseado no seu paralelismo implícito e otimização multi-tarefa [1]. Alguns dos algoritmos são bastante conhecidos, como otimização por enxames de partículas (PSO, *Particle Swarm Optimization*), Colônia de Abelhas artificiais (ABC, *Artificial Bee Colony*), Busca por cardumes (FSS, *Fish School Search*), dentre outros [2,3]. É possível encontrar aplicações das mais diversas como otimização real, inteira e binária e aglomeração (do inglês clustering) [4].

Os algoritmos mais usuais têm soluções candidatas (agentes) coexistindo durante todo o processo iterativo [5]. Estes se comunicam por algum mecanismo pré-determinado e irão gerar novas soluções a partir das existentes. Todavia, tais condições podem ser melhoradas.

O aprendizado por reforço (RL) [6,7] é uma área de aprendizado de máquina centrada na maneira como os agentes de software devem executar ações em um ambiente, a fim de maximizar alguma noção de recompensa cumulativa. Pode-se estender essa ideia aos agentes supracitados, de modo que estes possam alterar seu comportamento à medida que as condições da busca sejam variáveis. Isto implica que cada solução candidata pode seguir a busca como uma partícula (do PSO) em determinado instante, ou como uma abelha (do ABC) no momento seguinte, a depender da resposta de reforço recebida.

O RL já está presente na literatura de inteligência computacional, mas basicamente para atualizar os valores dos parâmetros livres de um mesmo algoritmo. O objetivo deste projeto é investigar as formas como os algoritmos podem trocar informações baseada em reforço para aumentar a capacidade de solução de problemas complexos e depois utilizar estas abordagens para resolver problemas reais de engenharia.

Referências Bibliográficas

1. Castro, L. N., *Fundamentals of Natural Computing: Basic Concepts, Algorithms and Applications*. Chapman & May, 2006.
2. Bonabeau, E., Dorigo, M., Theraulaz, G., *Swarm Intelligence: From Natural to Artificial Systems*, [S.l.: s.n.], 2019.
3. Engelbrecht, A. *Fundamentals of Computational Swarm Intelligence*. [S.l.]: Wiley & Sons. ISBN 0-470-09191-6
4. Figueiredo, E., Macedo, M. G. M., Siqueira, H., Santana JR., C. J., Gokhale, A., Bastos Filho, C. J. A., *Swarm intelligence for clustering A systematic review with new perspectives on data mining*. *Engineering Applications of Artificial Intelligence*, v. 82, p. 313-329, 2019.
5. Kennedy, J., Eberhart, R., *Swarm Intelligence*, [S.l.: s.n.], ISBN 1-55860-595-9
6. Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., ... & Wierstra, D. (2015). Continuous control with deep reinforcement learning. arXiv preprint arXiv:1509.02971.
7. Duan, Y., Chen, X., Houthoof, R., Schulman, J., & Abbeel, P. (2016, June). Benchmarking deep reinforcement learning for continuous control. In *International Conference on Machine Learning* (pp. 1329-1338).