



Híbrido Tático-Enxame: Uma Arquitetura Fluida Otimizada por PSO para Futebol de Robôs

Pablo Belinaso Millani

¹Universidade Federal de Santa Maria, Taura Bots
Santa Maria – Rio Grande do Sul – Brasil

millani@redes.ufsm.br

Resumo. O controle de sistemas multi-robô é marcado por um dilema entre a coerência de arquiteturas centralizadas e a robustez de enxames descentralizados. Este artigo propõe a arquitetura Híbrido Tático-Enxame, que une a visão estratégica de um componente centralizado ("Treinador") com a execução adaptativa de um enxame ("Jogadores"). A inovação fundamental não está apenas na fusão de técnicas como Flocking e ACO, mas no uso da Otimização por Enxame de Partículas (PSO) para sintonizar cientificamente a sinergia entre a orientação global e a auto-organização local. Apresenta-se um framework teórico e uma metodologia de validação que projeta uma arquitetura superior em desempenho e, crucialmente, em resiliência, demonstrando uma "degradação graciosa" em caso de falhas — um avanço em relação aos paradigmas puros.

Abstract. The control of multi-robot systems is marked by a dilemma between the coherence of centralized architectures and the robustness of decentralized swarms. This paper proposes the Tactical-Swarm Hybrid architecture, which unites the strategic vision of a centralized component ("Coach") with the adaptive execution of a swarm ("Players"). The key innovation lies not only in merging techniques like Flocking and ACO, but in using Particle Swarm Optimization (PSO) to scientifically tune the synergy between global guidance and local self-organization. We present a theoretical framework and a validation methodology that projects a superior architecture in terms of performance and, crucially, resilience, demonstrating "graceful degradation" in case of failures — an advancement over pure paradigms.

1. Introdução

A coordenação eficaz de equipes de robôs em ambientes dinâmicos e adversariais, como o Futebol de Robôs, é um desafio central na robótica de enxames [G et al. 2024, Brambilla et al. 2013]. A literatura é dominada pela dicotomia entre arquiteturas centralizadas (coerentes, mas vulneráveis [Stone and Veloso 2000]) e descentralizadas (robustas, mas sem estratégia global [Brambilla et al. 2013]). Embora meta-heurísticas como PSO [Kennedy and Eberhart 1995] e a hibridização de algoritmos de enxame [Luo and Yu 2023] existam, sua aplicação é focada em subproblemas isolados [Zhang and et al. 2013], faltando um *framework* que otimize a *interação* entre a tática global e a auto-organização. Este artigo propõe a arquitetura Híbrido Tático-Enxame para preencher essa lacuna, usando PSO para otimizar o *trade-off* entre disciplina de formação e flexibilidade de papéis.

2. A Arquitetura Híbrido Tático-Enxame

A arquitetura decompõe o problema em dois componentes sinérgicos: um "Treinador Tático" centralizado e um "Enxame de Jogadores" descentralizado.




Figura 1. Diagrama da Arquitetura Híbrido Tático-Enxame. O Treinador (centralizado) analisa o estado global e envia o Ponto de Referência Tático (PRT) para o Enxame (descentralizado), que o utiliza como guia global para suas regras locais (Flocking/ACO).

2.1. O Treinador Tático (Componente Centralizado)

O Treinador é uma entidade computacional com visão global do jogo. Sua função não é ditar ações, mas sim analisar a partida e disseminar um "Ponto de Referência Tático" (PRT) para a equipe, representando a intenção estratégica (ex: um ponto vantajoso para ataque ou defesa).

2.2. O Enxame de Jogadores (Componente Descentralizado)

Os agentes (Jogadores) utilizam o PRT como orientação global, mas executam suas ações com base em regras locais. A execução descentralizada é regida por dois mecanismos principais que atuam em conjunto:

Coesão da Formação com Flocking Inspirado em [Reynolds 1987], o movimento de cada agente é governado por uma soma ponderada de quatro vetores: três regras clássicas (Separação, Alinhamento, Coesão) e uma quarta, a **Atração Tática** (em direção ao PRT). A velocidade final V_{final} é dada por:

$$V_{\text{final}} = w_s V_s + w_a V_a + w_c V_c + w_t V_t \quad (1)$$

Os pesos $\{w_s, w_a, w_c, w_t\}$ são hiperparâmetros cruciais e o alvo primário da nossa otimização.

Atribuição Dinâmica de Papéis com ACO A divisão de trabalho emerge através da Otimização por Colônia de Formigas (ACO) [Dorigo et al. 1996], um desafio central também em abordagens modernas de aprendizado por reforço [Chen et al. 2024]. Feromônios digitais representam a atratividade de papéis táticos (ex: "atacante"). A probabilidade P_{ij} de um agente i escolher o papel j é:

$$P_{ij}(t) = \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{k \in \text{papeis}} [\tau_{ik}(t)]^\alpha \cdot [\eta_{ik}]^\beta} \quad (2)$$

Onde τ_{ij} é o feromônio, η_{ij} é uma heurística (ex: inverso da distância à bola), e α, β são hiperparâmetros também otimizados.

3. Metodologia de Otimização e Validação Proposta

A transição do conceito para a validação empírica exige um *framework* experimental rigoroso, aqui proposto de forma teórica.

3.1. Otimização Global via PSO

A inovação central é o uso de PSO [Kennedy and Eberhart 1995] para otimizar a **arquitetura como um todo**. Cada partícula do PSO é um vetor completo de hiperparâmetros da arquitetura (pesos de Flocking $\{w\}$, coeficientes da ACO $\{\alpha, \beta\}$, etc.), buscando a combinação mais eficaz. A avaliação de cada partícula é feita via simulação na plataforma RoboCup 2D Simulation League [Kitano et al. 1997], um *benchmark* ainda ativo [RoboCup Federation 2023]. O desempenho é medido por uma **Função de Aptidão**:

$$\text{Aptidão} = w_g \cdot (\text{Gols}_M) - w_s \cdot (\text{Gols}_S) + w_p \cdot (\text{PosseDeBola}) \quad (3)$$

Onde os pesos w_g, w_s, w_p refletem a filosofia tática desejada.

3.2. Cenários de Teste e Hipóteses

Propõe-se uma análise comparativa contra duas *baselines*: uma **Centralizada** (e.g., Algoritmo Húngaro [Kuhn 1955]) e uma **Descentralizada** (agentes puramente reativos, e.g., o mais próximo da bola ataca). O cenário de teste mais crítico foca na **robustez**: o Treinador Tático é deliberadamente desativado. A hipótese (H2) é que a equipe Híbrido Tático-Enxame exibirá uma **degradação graciosa** de desempenho, mantendo a coesão local, em contraste com o colapso funcional da *baseline* centralizada.

4. Resultados Esperados e Conclusão

Sendo este um trabalho de natureza teórica, projeta-se que a otimização via PSO validará as hipóteses H1 (superar *baselines*) e H2 (demonstrar resiliência). Esta arquitetura resolve o dilema centralizado-descentralizado através de um *framework* de otimização global que sintoniza a sinergia entre estratégia e emergência. Conclui-se que esta abordagem é um modelo promissor para equipes de robôs taticamente coerentes e resilientemente adaptativos. O passo futuro fundamental é a implementação prática, explorando a substituição do Treinador por um agente de Aprendizagem por Reforço (RL) [Sutton and Barto 2018], alinhando-se às tendências de MARL para o aprendizado de estratégias autônomas [List et al. 2024].

Referências

- Brambilla, M., Ferrante, E., Birattari, M., and Dorigo, M. (2013). Swarm robotics: a review from the swarm engineering perspective. *Swarm Intelligence*, 7(1):1–41.
- Chen, H., Wu, F., and Li, M. (2024). Dynamic role-graph reinforcement learning for multi-agent collaborative coding systems. In *International Conference on Learning Representations (ICLR) Workshop on AI for Agent-based Modeling*.
- Dorigo, M., Maniezzo, V., and Colorni, A. (1996). Ant system: optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 26(1):29–41.
- G, K., K, K., and R, S. (2024). Swarm intelligence-based multi-robotics: A comprehensive review. *Technologies*, 4(4):64.
- Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-International Conference on Neural Networks*, volume 4, pages 1942–1948. IEEE.
- Kitano, H., Asada, M., Kuniyoshi, Y., Noda, I., and Osawa, E. (1997). Robocup: A challenge problem for ai and robotics. In *RoboCup-97: Robot Soccer World Cup I*, pages 1–19. Springer.
- Kuhn, H. W. (1955). The hungarian method for the assignment problem. *Naval Research Logistics Quarterly*, 2(1-2):83–97.
- List, T., König, J., Müller, R., Küfer, J., Klemm, S., Sprenger, J., Sprenger, B., Roth, H., Eberhard, M., Hein, W., Frank, J., Klink, S., Lohnert, M., and Martius, G. (2024). Marladona towards cooperative team play using multi-agent reinforcement learning.
- Luo, Q. and Yu, J., editors (2023). *Recent Advances in Swarm Intelligence Algorithms and Their Applications*. MDPI - Multidisciplinary Digital Publishing Institute.
- Reynolds, C. W. (1987). Flocks, herds and schools: A distributed behavioral model. *ACM SIGGRAPH Computer Graphics*, 21(4):25–34.
- RoboCup Federation (2023). Final rankings - robocupsoccer simulation 2d league 2023. Accessed: 2024-08-20.
- Stone, P. and Veloso, M. (2000). Multiagent systems: A survey from a machine learning perspective. *Autonomous Robots*, 8(3):345–383.
- Sutton, R. S. and Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press.
- Zhang, H. and et al. (2013). Soccer robot path planning based on particle swarm immune optimization algorithm. In *Proceedings of the 25th Chinese Control and Decision Conference (CCDC)*, pages 3755–3759. IEEE.