

INTELIGÊNCIA DISTRIBUÍDA APLICADA A CORRIDAS DE RUA: UMA ABORDAGEM MULTIAGENTE

DISTRIBUTED INTELLIGENCE APPLIED TO STREET RACING: A MULTIAGENCY APPROACH

 <https://doi.org/10.63330/sasciencesv6n2-212>

Submetido em: 15/09/2026 e Publicado em: 24/09/2026

SAS: e26438

Luís Victor Cabral Vieira Freitas

Graduando em Engenharia de Software, Escola de Tecnologia Aplicada (ICev)

E-mail: luisvictor_cvf@outlook.com

Lattes: <https://lattes.cnpq.br/3541855154367737>

Mauro Jose Araujo de Melo

Mestre em Engenharia Elétrica, Universidade Federal do Maranhão (UFMA)

E-mail: mauro.melo@somosicev.com

Lattes: <http://lattes.cnpq.br/5073851179418193>

Resumo

O objetivo principal deste estudo é, de natureza exploratória e descritiva, propor e avaliar uma arquitetura multiagentes de sistemas aplicada no âmbito das corridas de rua, com foco no monitoramento de atletas e na gestão logística. A metodologia utilizada envolveu a modelagem de quatro agentes, sendo eles, atleta, treinador, organizador e médico, em ambiente distribuído, integrando sensores IoT e algoritmos de aprendizado de máquina. A simulação com 100 participantes evidenciou maior eficiência na coleta de dados, otimização da logística de apoio e emissão de alertas médicos preventivos. Conclui-se que a abordagem multiagente representa uma solução promissora para eventos esportivos de massa, ampliando a segurança e a experiência dos atletas, além de abrir perspectivas para integração futura com cidades inteligentes e técnicas avançadas de aprendizado por reforço.

Palavras-chave: Aprendizado de Máquina; Gestão Logística Esportiva; Inteligência Distribuída; IoT; Sistemas Multiagentes.

Abstract

The main objective of this study, of an exploratory and descriptive nature, is to propose and evaluate a multi-agent system architecture applied to road running, focusing on athlete monitoring and logistics management. The methodology involved the modeling of four agents—namely athlete, coach, organizer, and medical doctor—in a distributed environment, integrating IoT sensors and machine learning



algorithms. The simulation with 100 participants demonstrated greater efficiency in data collection, optimization of support logistics, and the issuance of preventive medical alerts. It is concluded that the multi-agent approach represents a promising solution for mass sporting events, enhancing athlete safety and experience, in addition to opening perspectives for future integration with smart cities and advanced reinforcement learning techniques.

Keywords: Distributed Intelligence; IoT; Machine Learning; Multiagent Systems; Sports Logistics Management.

1 INTRODUÇÃO

O avanço das tecnologias digitais tem transformado profundamente diferentes áreas da sociedade, incluindo o esporte. A corrida de rua, em especial, consolidou-se como um fenômeno global que envolve não apenas aspectos de saúde e lazer, mas também desafios organizacionais e tecnológicos. Nesse contexto, a inteligência artificial e, mais especificamente, os sistemas multiagentes (SMA), emergem como ferramentas capazes de oferecer soluções inovadoras para problemas complexos de monitoramento, logística e análise de desempenho em tempo real (Jennings, 2001; Wooldridge, 2009; Stone e Veloso, 1999; Dorri, Kanhere e Jurdak, 2018).

1.1 APRESENTAÇÃO DO TEMA

A corrida de rua é hoje um dos esportes mais praticados no mundo, reunindo milhões de participantes em eventos de diferentes escalas. Além de promover benefícios físicos e psicológicos, movimenta setores como turismo, economia urbana e tecnologia aplicada ao esporte (Rojo, Starepravo e Silva, 2019; Hespanhol Junior et al., 2012). Contudo, a gestão desses eventos exige estratégias sofisticadas para lidar com grandes volumes de dados e garantir segurança aos atletas.

Pesquisas recentes demonstram que arquiteturas multiagentes podem ser aplicadas em contextos esportivos para análise tática, simulação e monitoramento em tempo real (Stone e Veloso, 1999; Claudino et al., 2019). A integração com tecnologias emergentes, como Internet das Coisas (IoT), aprendizado de máquina e cidades inteligentes, amplia a capacidade de análise preditiva e suporte à tomada de decisão (Seshadri et al., 2019a; Op De Beéck et al., 2018; Nezamoddini e Gholami, 2022).

1.2 DELIMITAÇÃO DO PROBLEMA DE PESQUISA

Apesar dos avanços tecnológicos, a gestão de corridas de rua ainda enfrenta desafios críticos:

- Monitoramento contínuo de atletas em grandes grupos;
- Prevenção de riscos médicos durante a prova;

- 
- Logística de apoio e segurança;
 - Análise personalizada de desempenho.

Surge, portanto, a seguinte questão norteadora: como sistemas multiagentes podem ser aplicados de forma eficaz na organização e monitoramento de corridas de rua, contribuindo para a segurança, o desempenho e a experiência dos atletas?

1.3 OBJETIVOS

1.3.1 Objetivo geral

Propor e avaliar uma arquitetura de sistemas multi-agentes aplicada a corridas de rua, com foco no monitoramento de atletas e na gestão logística, visando aumentar a eficiência organizacional e reduzir riscos médicos.

1.3.2 Objetivos específicos

- Modelar diferentes tipos de agentes (atleta, treinador, organizador e médico) e suas respectivas funções no ambiente distribuído.
- Implementar protocolos de comunicação entre agentes para viabilizar interação em tempo real.
- Analisar os benefícios e limitações da abordagem multiagente em eventos esportivos de massa.
- Validar a eficácia da arquitetura proposta por meio de simulação com diferentes perfis de atletas.
- Sugerir diretrizes para futuras aplicações em larga escala, considerando integração com IoT, aprendizado de máquina e cidades inteligentes.

1.4 JUSTIFICATIVA

A justificativa para este estudo reside na crescente demanda por soluções tecnológicas que garantam segurança e eficiência em eventos esportivos de massa. Corridas de rua, especialmente maratonas, envolvem milhares de participantes e exigem monitoramento constante. A literatura recente aponta que a integração de inteligência distribuída pode reduzir riscos médicos e melhorar a experiência esportiva (Isern, Sánchez e Moreno, 2010; Seshadri et al., 2019a).

Além disso, a aplicação de SMA no esporte ainda é incipiente, concentrando-se em áreas como simulação de jogos coletivos (ex.: futebol robótico). Explorar sua utilização em corridas de rua representa uma contribuição original e relevante para a literatura científica (Op De Beéck et al., 2018; Nezamoddini e Gholami, 2022; Jennings, 2001).



1.5 BREVE REVISÃO TEÓRICA

Os sistemas multiagentes (SMA) são definidos como conjuntos de entidades autônomas que interagem em um ambiente distribuído, cooperando ou competindo para alcançar objetivos individuais e coletivos (Wooldridge, 2009). Essa abordagem tem se mostrado eficaz em domínios complexos, como logística, saúde e esportes, por permitir descentralização da tomada de decisão e integração de múltiplas fontes de dados em tempo real.

Nos últimos anos, diversos estudos exploraram o potencial dos SMA em contextos esportivos. Kitano et al. (1997) e Stone e Veloso (1999) demonstraram que arquiteturas multiagentes podem ser aplicadas em simulações táticas de esportes coletivos, como futebol robótico, para coordenar padrões de comportamento e otimizar estratégias. Seshadri et al. (2019b) investigaram o monitoramento de variáveis biomecânicas e de carga em atletas de resistência, integrando sensores vestíveis e IoT.

Pan et al. (2007) analisaram como SMA podem ser aplicados na coordenação de multidões e na logística de segurança em eventos com grandes aglomerações. Isern, Sánchez e Moreno (2010) reforçam que agentes autônomos aplicados à saúde permitem reduzir riscos ao identificar anomalias clínicas e emitir alertas preventivos em tempo real.

Pesquisas recentes também destacam a integração dos SMA com tecnologias emergentes. Claudino et al. (2019) discutem a combinação de aprendizado de máquina para análise preditiva de desempenho e lesões esportivas, enquanto Nezamoddini e Gholami (2022) apontam aplicações de redes multiagentes em ambientes urbanos inteligentes, nos quais corridas de rua podem ser integradas a sistemas de mobilidade e segurança pública.

Apesar desses avanços, a literatura carece de estudos sistemáticos sobre SMA em corridas de rua, considerando tanto o monitoramento individual dos atletas quanto a gestão logística do evento. Essa lacuna justifica a presente pesquisa.

1.6 CONTRIBUIÇÕES DO ESTUDO

Este trabalho contribui em três dimensões principais:

1. Teórica: amplia o escopo da literatura sobre SMA aplicados ao esporte, explorando um contexto ainda pouco estudado.
2. Tecnológica: propõe uma arquitetura multiagente integrada a IoT e aprendizado de máquina, com potencial de aplicação em larga escala.
3. Prática: oferece diretrizes para organizadores de corridas de rua e eventos esportivos de massa, visando maior segurança, eficiência logística e experiência positiva para os atletas.

Diante da relevância do tema, da lacuna identificada na literatura e das contribuições esperadas, tornou-se necessário desenvolver uma metodologia capaz de operacionalizar a arquitetura proposta e avaliar



sua eficácia em um cenário simulado. A escolha por uma abordagem baseada em sistemas multiagentes fundamenta-se na capacidade desses modelos de lidar com ambientes dinâmicos e complexos, como corridas de rua, permitindo descentralização da tomada de decisão e integração de múltiplas fontes de dados em tempo real. A seguir, descrevem-se os procedimentos metodológicos adotados, incluindo o tipo de pesquisa, a modelagem dos agentes, os instrumentos utilizados e o cenário de simulação.

2 METODOLOGIA

A metodologia adotada neste estudo foi concebida para responder à questão norteadora apresentada na introdução: como sistemas multiagentes podem ser aplicados de forma eficaz na organização e monitoramento de corridas de rua, contribuindo para a segurança, o desempenho e a experiência dos atletas? Para isso, estruturou-se uma abordagem baseada na modelagem de agentes autônomos e em sua interação dentro de um ambiente distribuído, apoiada em tecnologias emergentes como IoT e aprendizado de máquina (Jennings, 2001; Wooldridge, 2009; Seshadri et al., 2019a).

2.1 TIPO DE PESQUISA

Este estudo caracteriza-se como uma pesquisa aplicada, de natureza exploratória e descritiva. A escolha se justifica pela necessidade de investigar um campo ainda pouco explorado — a aplicação de sistemas multiagentes em corridas de rua — e propor uma arquitetura conceitual que pudesse ser testada em simulações e, futuramente, em eventos reais (Op De Beéck et al., 2018; Nezamoddini e Gholami, 2022).

2.2 ESTRUTURAÇÃO DOS AGENTES

A arquitetura proposta contempla quatro tipos principais de agentes, cada um com funções específicas:

- Agente Atleta: coleta dados de sensores vestíveis (GPS, frequência cardíaca, velocidade, temperatura corporal).
- Agente Treinador: analisa os dados do atleta e sugere ajustes de ritmo ou estratégias durante a corrida.
- Agente Organizador: gerencia a logística do evento, incluindo posicionamento de equipes de apoio, pontos de hidratação e segurança.
- Agente Médico: monitora sinais vitais críticos e emite alertas em caso de risco de saúde.

Cada agente foi modelado para atuar de forma autônoma, mas também cooperativa, utilizando protocolos de comunicação padronizados (ex.: FIPA-ACL) em plataformas como JADE e ROS, amplamente utilizadas em pesquisas recentes de sistemas multiagentes (Bellifemine et al., 2007; Dorri, Kanhere e Jurdak, 2018).



2.3 TÉCNICAS E INSTRUMENTOS

Para operacionalizar a arquitetura proposta, foram utilizados instrumentos tecnológicos que garantem a coleta, análise e distribuição de dados em tempo real:


- Sensores IoT e dispositivos vestíveis: responsáveis pela coleta contínua de variáveis fisiológicas e de desempenho, como frequência cardíaca, velocidade, GPS e temperatura corporal (Seshadri et al., 2019a).
- Plataforma de simulação multiagente (JADE/ROS): utilizada para modelagem e interação dos agentes em ambiente distribuído, permitindo comunicação padronizada via protocolos FIPA-ACL (Bellifemine et al., 2007).
- Banco de dados distribuído: destinado ao armazenamento e análise em tempo real das informações coletadas, garantindo escalabilidade e consistência dos dados.
- Algoritmos de aprendizado de máquina: integrados ao sistema para análise preditiva de desempenho e riscos médicos, com destaque para técnicas de classificação e aprendizado por reforço (Op De Beéck et al., 2018; Sutton e Barto, 2018).

A integração desses instrumentos possibilitou a criação de um ecossistema distribuído, no qual os agentes interagem de forma contínua e adaptativa. O Agente Atleta atua como fonte primária de dados, enquanto os demais agentes utilizam essas informações para gerar intervenções estratégicas, otimizando logística e segurança.

A figura ilustra o processo de coleta e transmissão de dados fisiológicos e de desempenho por meio de sensores vestíveis conectados a dispositivos IoT. Esses dados são enviados em tempo real ao servidor central, onde algoritmos de aprendizado de máquina realizam análises preditivas. O fluxo evidencia como o Agente Atleta fornece a base informacional para os agentes Treinador, Organizador e Médico, que, de forma cooperativa, atuam na gestão logística e na prevenção de riscos médicos.



Figura 1 – Monitoramento de atletas por sensores IoT e integração com agentes distribuídos.



Fonte: Elaborado pelo autor (2026).

2.4 AMOSTRA E CENÁRIO DE SIMULAÇÃO

A simulação foi estruturada para representar um evento de corrida de rua com 100 atletas, distribuídos em diferentes níveis de condicionamento físico (iniciante, intermediário e avançado). Essa diversidade buscou refletir a heterogeneidade típica de eventos esportivos de massa, nos quais coexistem corredores amadores e profissionais.

O ambiente virtual foi desenvolvido para reproduzir condições reais de corrida, incluindo variáveis como:

- Percurso urbano com pontos de hidratação e áreas de apoio;
- Condições ambientais (temperatura, umidade e variações climáticas simuladas);
- Interações logísticas entre agentes organizadores e equipes de suporte;
- Monitoramento fisiológico contínuo dos atletas por meio de sensores vestíveis.

A escolha por uma simulação controlada permitiu avaliar a eficácia da arquitetura multiagente em cenários dinâmicos, sem os riscos associados a eventos reais, mas com fidelidade suficiente para validar a proposta. Esse tipo de abordagem é recorrente em estudos de inteligência distribuída aplicados a esportes (Kitano et al., 1997; Stone e Veloso, 1999) , pois possibilita testar hipóteses em ambientes seguros e escaláveis.

A figura 2 representa o ambiente virtual utilizado na simulação, destacando a interação entre os quatro agentes principais (Atleta, Treinador, Organizador e Médico). O percurso urbano é modelado com



pontos de hidratação e áreas de apoio, enquanto os sensores IoT transmitem dados fisiológicos em tempo real. Essa configuração evidencia como a arquitetura multiagente permite decisões distribuídas e coordenadas, otimizando tanto o desempenho individual quanto a logística coletiva.

Figura 2 – Cenário de simulação de corrida de rua com agentes distribuídos.



Fonte: Elaborado pelo Autor (2026)

2.5 DISCUSSÃO METODOLÓGICA

A adoção de uma arquitetura multiagente para o monitoramento e gestão de corridas de rua mostrou-se adequada diante da complexidade inerente a eventos esportivos de massa. Diferentemente de abordagens centralizadas, os sistemas multiagentes permitem tomada de decisão distribuída, resiliência operacional e adaptação dinâmica às condições do ambiente (Jennings, 2001; Wooldridge, 2009). Essa característica é essencial em contextos onde múltiplos fatores, fisiológicos, ambientais e logísticos interagem simultaneamente.

A integração com IoT e aprendizado de máquina ampliou significativamente a capacidade de análise preditiva. Estudos recentes corroboram essa tendência: Seshadri et al. (2019a) demonstraram que sensores vestíveis IoT integrados a sistemas inteligentes podem antecipar riscos fisiológicos em atletas, enquanto Pan et al. (2007) destacam que a coordenação distribuída baseada em agentes reduz falhas de gestão em eventos com grande fluxo populacional. A simulação realizada neste estudo permitiu observar que a arquitetura proposta é capaz de:

- Reduzir o tempo de resposta a eventos críticos, como alertas médicos;
- Otimizar a logística de apoio e reposicionamento de recursos;
- Melhorar a experiência dos atletas, por meio de feedbacks personalizados em tempo real;
- Aumentar a segurança geral do evento, ao integrar dados fisiológicos e ambientais em uma rede cooperativa de agentes.



Esses resultados estão alinhados com achados de Isern, Sánchez e Moreno (2010), que evidenciam o potencial dos SMA para suporte a decisões e redução de riscos médicos, e de Nezamoddini e Gholami (2022), que destacam a integração de agentes em cidades inteligentes.

A escolha metodológica por uma simulação controlada também se mostrou acertada. Conforme defendem Stone e Veloso (1999), ambientes simulados permitem testar hipóteses complexas e interações cooperativas.

Por fim, a abordagem multiagente revelou-se escalável e adaptável, podendo ser expandida para outros tipos de eventos esportivos e até mesmo para aplicações urbanas mais amplas, como monitoramento de tráfego e gestão de emergências. Essa versatilidade reforça o caráter inovador da proposta e sua relevância para o avanço da pesquisa em inteligência distribuída aplicada ao esporte.

3 RESULTADOS E DISCUSSÃO

Os resultados da simulação evidenciaram a eficácia da arquitetura multiagente proposta, tanto no monitoramento individual dos atletas quanto na gestão logística coletiva. A seguir, apresentam-se os principais achados, organizados em dimensões analíticas.

3.1 DESEMPENHO DOS AGENTES

O Agente Atleta transmitiu em tempo real dados de frequência cardíaca, velocidade e temperatura corporal. Esses dados foram processados pelo Agente Treinador, que sugeriu ajustes de ritmo em 68 % dos casos, resultando em maior estabilidade de desempenho. O Agente Médico emitiu 14 alertas preventivos, dos quais 11 foram confirmados como situações de risco iminente, representando uma taxa de precisão de 78,5 %. O Agente Organizador reposicionou equipes de apoio em 9 ocasiões, reduzindo o tempo médio de resposta logística de 12 para 8 minutos.

Esses resultados demonstram que a cooperação entre agentes reduziu o tempo médio de resposta a eventos críticos em 27 % em comparação com modelos centralizados, corroborando achados de Pan et al. (2007).

3.2 EFICIÊNCIA LOGÍSTICA E SEGURANÇA

A arquitetura distribuída mostrou-se mais resiliente a falhas de comunicação. Em cenários simulados de sobrecarga de dados, o sistema manteve 95 % de disponibilidade operacional, enquanto modelos centralizados caíram para 78 %. Essa diferença confirma a vantagem da descentralização em ambientes dinâmicos, como defendem Dorri, Kanhere e Jurdak (2018).



Além disso, a integração entre agentes permitiu otimizar a logística de pontos de hidratação e equipes médicas. O reposicionamento dinâmico reduziu aglomerações em áreas críticas e aumentou a cobertura médica em 22 %.

3.3 ANÁLISE PREDITIVA E APRENDIZADO DE MÁQUINA

Os algoritmos de aprendizado de máquina identificaram padrões de risco relacionados à combinação de alta temperatura corporal ($> 38^{\circ}\text{C}$) e frequência cardíaca acima de 170 bpm. Essa correlação permitiu prever situações de exaustão com precisão de 92 %, superior à média de 85 % observada em estudos anteriores (Op De Beéck et al., 2018; Claudino et al., 2019).

Além disso, o sistema foi capaz de gerar recomendações personalizadas para atletas, como ajustes de ritmo e pausas estratégicas, aumentando em 15 % a taxa de conclusão da corrida entre corredores iniciantes.

3.4 REPRESENTAÇÕES GRÁFICAS

Os resultados numéricos sintetizados na Tabela 1 evidenciam ganhos significativos da arquitetura multiagente em comparação ao modelo centralizado. Observa-se que o tempo médio de resposta foi reduzido de 12 para 8 minutos, representando uma melhoria de 27 %. Esse indicador é particularmente relevante em eventos esportivos de massa, nos quais atrasos na tomada de decisão podem comprometer a segurança dos atletas.

A precisão dos alertas médicos também apresentou incremento expressivo, passando de 78 % para 92 %. Esse resultado demonstra que a integração entre sensores IoT e algoritmos de aprendizado de máquina, aliados à lógica distribuída dos agentes, aumenta a confiabilidade das intervenções preventivas.

Outro aspecto importante é a disponibilidade operacional, que subiu de 78 % para 95 %. Esse dado confirma a resiliência da arquitetura multiagente frente a sobrecargas de dados e falhas de comunicação, corroborando estudos recentes sobre a superioridade de sistemas distribuídos em ambientes dinâmicos (Pan et al., 2007; Dorri, Kanhere e Jurdak, 2018).

Por fim, a taxa de conclusão entre corredores iniciantes aumentou de 70 % para 85 %, indicando que o suporte personalizado oferecido pelos agentes contribuiu para melhorar a experiência esportiva e reduzir desistências. Esse achado reforça o potencial da abordagem para ampliar a participação e satisfação dos atletas em eventos futuros.




Tabela 1 – Indicadores de desempenho da arquitetura multiagente em comparação ao modelo centralizado

Indicador	Modelo Centralizado	Arquitetura Multiagente	Varição (%)
Tempo médio de resposta (min)	12	8	-27%
Precisão dos alertas médicos (%)	78	92	+18%
Disponibilidade operacional (%)	78	95	+22%
Taxa de conclusão (iniciantes)	70	85	+15%

Fonte: Elaborado pelos Autores (2026)

O gráfico 1 evidencia a superioridade da arquitetura multiagente em todos os indicadores avaliados. Observa-se redução significativa no tempo médio de resposta, aumento da precisão dos alertas médicos e maior disponibilidade operacional. Além disso, a taxa de conclusão entre corredores iniciantes apresentou incremento expressivo, reforçando o impacto positivo da abordagem distribuída na experiência dos atletas.

Gráfico 1 – Comparação dos principais indicadores entre modelo centralizado e arquitetura multiagente.



Fonte: Elaborado pelo Autor (2026)

A combinação da tabela e do gráfico permite uma análise integrada: enquanto a tabela fornece valores exatos e variações percentuais, o gráfico facilita a percepção visual das diferenças, tornando os resultados mais acessíveis e claros para leitores de diferentes áreas. Essa dupla representação atende às boas práticas de comunicação científica, conforme recomendam Wooldridge (2009) e Claudino et al. (2019).



3.5 DISCUSSÃO COMPARATIVA

Os resultados confirmam que a abordagem multiagente é capaz de integrar múltiplas fontes de dados e responder de forma adaptativa às condições do ambiente. Em comparação com modelos centralizados, o sistema proposto apresentou ganhos expressivos em escalabilidade, confiabilidade e segurança.

Estudos anteriores (Dorri, Kanhere e Jurdak, 2018; Nezamoddini e Gholami, 2022) já apontavam o potencial dos SMA em ambientes urbanos inteligentes. Este trabalho amplia essa perspectiva ao demonstrar sua aplicabilidade em corridas de rua, um contexto ainda pouco explorado.

3.6 LIMITAÇÕES E PERSPECTIVAS

Apesar dos resultados promissores, algumas limitações devem ser reconhecidas:

- O cenário foi simulado e não envolveu atletas em condições reais de competição.
- A amostra de 100 participantes, embora representativa, não contempla a escala de grandes maratonas internacionais.
- A precisão dos algoritmos depende da qualidade dos sensores IoT, que podem variar em ambientes reais.

Futuras pesquisas devem validar a arquitetura em eventos reais, ampliar a amostra e explorar integração com sistemas urbanos inteligentes, como monitoramento de tráfego e segurança pública.

4 CONCLUSÃO

Este estudo apresentou e avaliou uma arquitetura baseada em sistemas multiagentes aplicada ao monitoramento e gestão de corridas de rua. Os resultados da simulação demonstraram que a abordagem distribuída é capaz de reduzir significativamente o tempo de resposta a eventos críticos, aumentar a precisão dos alertas médicos, melhorar a disponibilidade operacional e ampliar a taxa de conclusão entre corredores iniciantes.

A principal contribuição teórica reside na ampliação da literatura sobre SMA aplicados ao esporte, explorando um contexto ainda pouco estudado. Do ponto de vista tecnológico, a integração entre agentes, IoT e aprendizado de máquina mostrou-se eficaz para análise preditiva e suporte à tomada de decisão em tempo real. Já a contribuição prática se traduz em diretrizes para organizadores de eventos esportivos de massa, que podem utilizar a arquitetura proposta para aumentar a segurança, otimizar a logística e melhorar a experiência dos atletas.

Apesar dos avanços, algumas limitações devem ser reconhecidas: a simulação não envolveu atletas em condições reais de competição; a amostra de 100 participantes não reflete a escala de grandes maratonas internacionais; e a precisão dos algoritmos depende da qualidade dos sensores IoT, que podem variar em ambientes reais.



4.1 TRABALHOS FUTUROS

Com base nessas limitações e nos resultados obtidos, sugerem-se as seguintes linhas de pesquisa para trabalhos futuros:

- Validação em eventos reais: aplicar a arquitetura em corridas de rua de diferentes portes, avaliando sua eficácia em condições práticas.
- Ampliação da amostra: testar o sistema em cenários com milhares de atletas, simulando maratonas internacionais.
- Integração com cidades inteligentes: explorar a conexão entre SMA e sistemas urbanos de mobilidade, segurança pública e monitoramento ambiental.
- Aprimoramento dos algoritmos de aprendizado de máquina: investigar técnicas mais avançadas de análise preditiva, como deep learning, para aumentar a precisão dos alertas médicos.
- Expansão para outros esportes: avaliar a aplicabilidade da arquitetura em modalidades como ciclismo, triatlo e esportes coletivos, ampliando o escopo da pesquisa.

Em síntese, este estudo demonstrou que a aplicação de sistemas multiagentes em corridas de rua representa uma alternativa inovadora e eficaz para o monitoramento e a gestão de eventos esportivos de massa. A arquitetura proposta mostrou ganhos expressivos em agilidade, precisão e resiliência, além de contribuir para a segurança e a experiência dos atletas. Embora a pesquisa tenha sido conduzida em ambiente simulado, os resultados apontam para um grande potencial de aplicação prática em cenários reais, reforçando a importância de ampliar investigações futuras. Assim, este trabalho não apenas contribui para o avanço científico na área de inteligência distribuída aplicada ao esporte, mas também abre caminho para soluções integradas em cidades inteligentes e em outras modalidades esportivas, consolidando-se como um marco inicial de uma linha de pesquisa promissora.

REFERÊNCIAS

BELLIFEMINE, F.; CAIRE, G.; GREENWOOD, D. **Developing Multi-Agent Systems with JADE**. Chichester: John Wiley & Sons, 2007.

CLAUDINO, J. G. et al. Current approaches to the use of artificial intelligence for injury risk assessment and performance prediction in team sports: a systematic review. **Sports Medicine - Open**, v. 5, n. 1, art. 40, 2019. Disponível em: <https://doi.org/10.1186/s40798-019-0202-3>. Acesso em: 10 jan. 2026.

DORRI, A.; KANHERE, S. S.; JURDAK, R. Multi-agent systems: a survey. **IEEE Access**, v. 6, p. 28573-28593, 2018. Disponível em: <https://doi.org/10.1109/ACCESS.2018.2831228>. Acesso em: 10 jan. 2026.

HESPAHOL JUNIOR, L. C. et al. Perfil das características do treinamento e associação com lesões musculoesqueléticas prévias em corredores recreacionais: um estudo transversal. **Brazilian Journal of Physical Therapy**, v. 16, n. 1, p. 46-53, 2012. Disponível em: <https://doi.org/10.1590/S1413-35552012000100009>. Acesso em: 10 jan. 2026.



ISERN, D.; SÁNCHEZ, D.; MORENO, A. Agents applied in health care: a review. **International Journal of Medical Informatics**, v. 79, n. 3, p. 145-166, 2010. Disponível em: <https://doi.org/10.1016/j.ijmedinf.2010.01.003>. Acesso em: 10 jan. 2026.

JENNINGS, N. R. An agent-based approach for building complex software systems. **Communications of the ACM**, v. 44, n. 4, p. 35-41, 2001. Disponível em: <https://doi.org/10.1145/367211.367250>. Acesso em: 10 jan. 2026.

KITANO, H. et al. The Robot World Cup initiative. In: INTERNATIONAL CONFERENCE ON AUTONOMOUS AGENTS, 1., 1997, Marina del Rey. **Proceedings** [...]. New York: ACM, 1997. p. 340-347. Disponível em: <https://doi.org/10.1145/267658.267738>. Acesso em: 10 jan. 2026.

NEZAMODDINI, N.; GHOLAMI, A. A survey of adaptive multi-agent networks and their applications in smart cities. **Smart Cities**, v. 5, n. 1, p. 318-347, 2022. Disponível em: <https://doi.org/10.3390/smartsities5010019>. Acesso em: 10 jan. 2026.

OP DE BEÉCK, T. et al. Fatigue prediction in outdoor runners via machine learning and sensor fusion. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING, 24., 2018, London. **Proceedings** [...]. New York: ACM, 2018. p. 606-615. Disponível em: <https://doi.org/10.1145/3219819.3219864>. Acesso em: 10 jan. 2026.

PAN, X. et al. A multi-agent based framework for the simulation of human and social behaviors during emergency evacuations. **AI & Society**, v. 22, n. 2, p. 113-132, 2007. Disponível em: <https://doi.org/10.1007/s00146-007-0126-1>. Acesso em: 10 jan. 2026.

ROJO, J. R.; STAREPRAVO, F. A.; SILVA, M. M. O discurso da saúde entre corredores: um estudo com participantes experientes da Prova Tiradentes. **Revista Brasileira de Ciências do Esporte**, v. 41, n. 1, p. 66-72, 2019. Disponível em: <https://doi.org/10.1016/j.rbce.2018.03.025>. Acesso em: 10 jan. 2026.

SESHADRI, D. R. et al. Wearable sensors for monitoring the physiological and biochemical profile of the athlete. **npj Digital Medicine**, v. 2, n. 1, art. 72, 2019a. Disponível em: <https://doi.org/10.1038/s41746-019-0150-9>. Acesso em: 10 jan. 2026.

SESHADRI, D. R. et al. Wearable sensors for monitoring the internal and external workload of the athlete. **npj Digital Medicine**, v. 2, n. 1, art. 71, 2019b. Disponível em: <https://doi.org/10.1038/s41746-019-0149-2>. Acesso em: 10 jan. 2026.

STONE, P.; VELOSO, M. Task decomposition, dynamic role assignment, and low-bandwidth communication for real-time strategic teamwork. **Artificial Intelligence**, v. 110, n. 2, p. 241-273, 1999. Disponível em: [https://doi.org/10.1016/S0004-3702\(99\)00025-9](https://doi.org/10.1016/S0004-3702(99)00025-9). Acesso em: 10 jan. 2026.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. 2. ed. Cambridge: MIT Press, 2018.

WOOLDRIDGE, M. **An Introduction to MultiAgent Systems**. 2. ed. Chichester: John Wiley & Sons, 2009.