

Evolución de los Sistemas Robóticos Multi-Agente: Del Control Distribuido a los Modelos de Lenguaje de Gran Escala.

Meneses Fandiño, Luisa F.^{a,b,*}, Gonzalez, Ander.^a, Calleja, Carlos.^a, Mancisidor, Aitziber.^b, Cabanes, Itziar.^b

^aIKERLAN, S. Coop., Basque Research and Technology Alliance (BRTA), 20500-Arrasate/Mondragón.

^bDepartamento de Ingeniería de Sistemas y Automática, Escuela de Ingeniería de Bilbao, Universidad del País Vasco (UPV/EHU), 48013-Bilbao

Resumen

Los Sistemas Robóticos Multi-Agente (Multi-Agent Robotic Systems, MARS) han surgido como una respuesta a la creciente demanda de cooperación, escalabilidad y robustez en aplicaciones donde múltiples robots deben actuar de forma coordinada en entornos dinámicos. Tradicionalmente, estos sistemas se han basado en arquitecturas de control distribuido y métodos algorítmicos de coordinación, que, si bien ofrecen garantías formales, presentan limitaciones frente a misiones abiertas, entornos no estructurados y sistemas heterogéneos. En los últimos años, la incorporación de enfoques basados en aprendizaje, así como de Modelos de Lenguaje de Gran Escala (Large Language Models, LLMs), han abierto nuevas posibilidades para dotar a los MARS de capacidades de inferencia basada en lenguaje, planificación de alto nivel y comunicación flexible. Estas arquitecturas permiten combinar ejecución distribuida con coordinación cognitiva centralizada, dando lugar a esquemas de control híbridos que integran aprendizaje, deliberación y control físico. Este artículo presenta una revisión del estado del arte que recorre la evolución desde sistemas robóticos individuales hasta MARS dirigidos por LLMs. La revisión de la literatura se organiza atendiendo a paradigmas de control, aprendizaje, arquitecturas de comunicación y mecanismos de ejecución, con el objetivo de identificar tendencias actuales y brechas abiertas de investigación relacionadas con seguridad, validación, simulación y diseño arquitectónico. De este modo, el trabajo proporciona una visión unificada del campo y orienta futuras líneas de investigación en robótica cooperativa cognitiva.

Palabras clave: Sistemas Multi-Agentes Robóticos, Modelos de lenguaje de Gran Escala, Control Distribuido.

Evolution of Multi-Agent Robotic Systems: From Distributed Control to Large Language Models.

Abstract

Multi-Agent Robotic Systems (MARS) have emerged as a response to the growing demand for cooperation, scalability, and robustness in applications where multiple robots must act in a coordinated manner in dynamic environments. Traditionally, these systems have been based on distributed control architectures and algorithmic coordination methods, which, while offering formal guarantees, have limitations when faced with open-ended missions, unstructured environments, and heterogeneous systems. In recent years, the incorporation of learning-based approaches, as well as Large Language Models (LLMs), has opened up new possibilities for equipping MARS with semantic reasoning, high-level planning, and flexible communication capabilities. These architectures allow distributed execution to be combined with centralized cognitive coordination, resulting in hybrid control schemes that integrate learning, deliberation, and physical control. This article presents a state of art review that traces the evolution from individual robotic systems to LLMs-driven MARS. The literature is organized according to control paradigms, learning, communication architectures, and execution mechanisms, with the aim of identifying current trends and open research gaps related to security, validation, simulation, and architectural design. This work provides a unified view of the field and guides future lines of research in cognitive cooperative robotics.

Keywords: Multi Agent Robotic systems, Large Language Models, Distributed control.

1. Introducción

La complejidad de las aplicaciones robóticas actuales ha impulsado el paso de plataformas aisladas hacia sistemas cooperativos y distribuidos. Tareas como búsqueda y rescate o logística industrial superan las capacidades de los Sistemas Robóticos Individuales (Single Robotic Systems, SRS), limitados en cobertura, robustez y eficiencia (Rakhmatillaev et al., 2025). Ante esto, la coordinación de múltiples entidades es esencial para distribuir tareas y compartir información bajo restricciones físicas y temporales.

Los Sistemas Multi-Robot (Multi-Robot Systems, MRS) abordan esta cooperación mediante algoritmos de asignación, planificación centralizada o métodos de optimización y subastas (Choi et al., 2025). Aunque efectivos en tareas definidas, su dependencia de funciones de coste rígidas limita la adaptación ante objetivos inciertos.

En paralelo, los Sistemas Multi-Agente (Multi-Agent Systems, MAS) introducen el concepto de agente autónomo con toma de decisiones descentralizada y protocolos de consenso (Heemels et al., 2013). Si bien los MAS permiten analizar formalmente la estabilidad y convergencia de sistemas autónomos, tradicionalmente se han estudiado en entornos abstractos con modelos de comunicación simplificados, omitiendo a menudo la interacción física directa con el entorno (Li et al., 2023).

La convergencia entre la teoría MAS y las plataformas robóticas induce a los Sistemas Multi-Agente Robóticos (Multi-Agent Robot Systems, MARS), en los que los agentes están físicamente implementados en un robot y deben coordinarse teniendo en cuenta la dinámica, la percepción, la comunicación imperfecta y las restricciones del hardware (Rasheed et al., 2022). A pesar de los avances logrados gracias a las arquitecturas de middleware, los simuladores de alta fidelidad y el control distribuido, los MARS continúan enfrentando dificultades para razonar sobre misiones complejas, interpretar objetivos de alto nivel y coordinar equipos heterogéneos de forma flexible (Martorell et al., 2024; Zhang et al., 2024).

En este contexto, los enfoques basados en el aprendizaje, como el Aprendizaje por Refuerzo (Reinforcement Learning, RL) (Kober et al., 2013), han permitido dotar a los sistemas robóticos de comportamientos adaptativos aprendidos a partir de la experiencia. Esta línea se ha extendido hacia el Aprendizaje por Refuerzo Multi-Agente (Multi-Agent Reinforcement Learning, MARL), donde múltiples agentes aprenden políticas de coordinación en entornos compartidos (Orr and Dutta, 2023). Sin embargo, estas técnicas presentan limitaciones importantes en términos de explicabilidad, generalización fuera de la distribución de entrenamiento y diseño de recompensas, lo que dificulta su uso en misiones abiertas y entornos no estructurados.

Más recientemente, los Modelos de Lenguaje de Gran Escala (Large Language Models, LLMs) se han incorporado como una capa de procesamiento lingüístico de alto nivel, capaz de modelar relaciones semánticas, descomponer tareas y facilitar la comunicación entre agentes (Liu et al., 2024b; Chen et al., 2024). Basados en el aprendizaje estadístico de patrones a partir de grandes entradas de texto, los LLMs operan sobre representaciones lingüísticas que permiten a los sistemas robóticos interpretar instrucciones potencialmente ambiguas, generar planes de acción a largo plazo y coordinar equipos heterogéneos.

Estas capacidades, aunque no implican razonamiento cognitivo en sentido estricto, contribuyen a una nueva etapa en el desarrollo de sistemas robóticos Multi-Agente con mayor autonomía funcional.

Este trabajo presenta un estado del arte que analiza la evolución desde sistemas robóticos individuales hasta sistemas robóticos Multi-Agente habilitados por LLMs. La literatura se organiza de forma progresiva en Sistema Robótico Individual (SRS), Sistemas Multi-Robot (MRS), Sistemas Multi-Agente (MAS), Sistemas Robóticos Multi-Agente (MARS) y Aprendizaje Cognitivo, con el objetivo de identificar tendencias, arquitecturas dominantes y brechas de investigación en comunicación, seguridad, simulación y validación.

El artículo se estructura de la siguiente manera. La Sección 2 describe la transición de SRS a MRS; la Sección 3 aborda la evolución hacia MARS; la Sección 4 analiza el papel del Aprendizaje por Refuerzo y del Aprendizaje por Refuerzo Multi-Agente en la coordinación robótica; la Sección 5 estudia la incorporación del Aprendizaje cognitivo mediante LLMs en los MARS; y la Sección 6 presenta la discusión de resultados y las oportunidades abiertas de investigación.

2. De Sistemas Robóticos individuales a Multi-Robot

Los sistemas robóticos autónomos se han concebido tradicionalmente como entidades aisladas, centradas en la percepción, planificación y control individual (Jordán, 2009). Sin embargo, en misiones de gran escala o críticas en tiempo, estas soluciones resultan insuficientes, lo que impulsa el uso de enfoques cooperativos.

Los MRS permiten abordar tareas de mayor complejidad mediante la distribución de funciones entre robots, introduciendo desafíos de coordinación, comunicación y resolución de conflictos (Roldán-Gómez et al., 2020). En este contexto, la Asignación de Tareas Multi-Robot (MRTA) es un problema clave, enfocado en optimizar la distribución de tareas para maximizar la eficiencia global (Chakraa et al., 2023). Sus soluciones se dividen en enfoques centralizados y descentralizados, destacando estos últimos por su escalabilidad y robustez, especialmente mediante algoritmos de subastas (Galati et al., 2023).

Los MRS han demostrado su eficacia en aplicaciones como búsqueda y rescate, UAV, exploración y transporte cooperativo, mejorando la eficiencia y tolerancia a fallos (Zhang et al., 2024; An et al., 2023). Además, pueden clasificarse en sistemas homogéneos y heterogéneos (Souto et al., 2024). No obstante, presentan limitaciones al depender de definiciones de tareas y funciones de utilidad estáticas, dificultando su adaptación a objetivos abiertos o semánticos.

Estas limitaciones impulsan la transición hacia enfoques basados en agentes, donde los robots adquieren mayor autonomía e interacción, dando lugar a los MARS, que se analizan en la siguiente sección.

3. De Sistemas Multi-Robot a Multi-Agentes Robóticos

En el contexto de los MAS, como se observa en la Figura 1, un agente se define como una entidad autónoma situada en un entorno, capaz de percibir, tomar decisiones, actuar para alcanzar objetivos individuales o colectivos e interactuar con

otros agentes mediante mecanismos de comunicación o coordinación. Esta noción enfatiza la autonomía y la toma de decisiones como rasgos distintivos frente a los enfoques puramente algorítmicos de coordinación.




Figura 1: Sistemas Multi-Agente (Heemels et al., 2013)

En paralelo al desarrollo de los MRS, la investigación en MAS surgió para modelar explícitamente la toma de decisiones descentralizada y la interacción compleja entre entidades autónomas. A diferencia de los MRS, donde los robots suelen actuar como ejecutores de tareas asignadas mediante algoritmos de optimización, los MAS introducen formalismos de consenso y control distribuido que proporcionan garantías sobre convergencia, estabilidad y robustez, incluso bajo información parcial o topologías dinámicas (Heemels et al., 2013). Esta base teórica permite implementar mecanismos de auto-organización mediante algoritmos de partición y agregación ampliamente adoptados en robótica cooperativa (Halsted et al., 2021; Testa et al., 2025).

Los MARS materializan el paradigma MAS al incorporar agentes físicos que operan en entornos dinámicos e inciertos. Esta transición incrementa significativamente la complejidad del sistema, lo que requiere arquitecturas de middleware robustas basadas en paradigmas como el Internet de las Cosas en Robótica (Internet of Robotic Things, IoRT) o en estándares industriales como ROS (Robot Operating System), que faciliten la interoperabilidad y el desacoplamiento entre la lógica de decisión y el hardware (Cuadros Zegarra et al., 2023; Flores et al., 2025). Sin embargo, la conectividad por sí sola resulta insuficiente; es necesario el uso de frameworks de análisis basados en modelos, como ATLAS (Harbin et al., 2021), para evaluar la robustez y el comportamiento ante fallos antes del despliegue físico.

Desde el punto de vista de la comunicación y la toma de decisiones, los MARS pueden organizarse siguiendo arquitecturas centralizadas, descentralizadas o híbridas. Mientras que los enfoques centralizados facilitan la coherencia y la optimización global a costa de problemas de escalabilidad y puntos únicos de fallo, las arquitecturas descentralizadas mejoran la robustez y la tolerancia a fallos, aunque con mayores dificultades de verificación formal (Heemels et al., 2013; Rasheed et al., 2022). En la práctica, la mayoría de los MARS modernos adoptan arquitecturas híbridas, en las que el razonamiento de alto nivel se gestiona de forma centralizada o semicentralizada y la ejecu-

ción permanece distribuida, como se observa en sistemas contemporáneos de coordinación cognitiva (Mandi et al., 2023).

A pesar de estos avances, revisiones recientes coinciden en que los MARS actuales aún enfrentan limitaciones importantes en términos de adaptabilidad cognitiva y flexibilidad cuando se enfrentan a misiones abiertas o descripciones de alto nivel (Rasheed et al., 2022)]. Estas carencias han impulsado, por un lado, la integración de técnicas de Aprendizaje por Refuerzo Multi-Agente para aprender políticas de coordinación seguras (Gu et al., 2024) como se plantea en la siguiente sección.

4. Aprendizaje por refuerzo Multi-Agente

Cuando la misión requiere la coordinación de múltiples entidades autónomas, el problema se traslada al ámbito del MARL. A diferencia del aprendizaje por refuerzo individual, el MARL debe enfrentarse a la no estacionariedad del entorno, en el que las políticas aprendidas por cada agente influyen directamente en las observaciones y recompensas de los demás, lo que dificulta la convergencia y la estabilidad del aprendizaje (Orr and Dutta, 2023).

Desde una perspectiva algorítmica, el MARL no se restringe a un único tipo de representación o de modelo. Los primeros enfoques se basan en métodos tabulares, aprendizaje independiente, formulaciones desde la teoría de juegos y mecanismos de coordinación explícita, con políticas discretas o parametrizaciones simples (Zhang et al., 2021). Sin embargo, estos métodos presentan limitaciones de escalabilidad cuando el número de agentes, estados u observaciones crece, lo que ha motivado la adopción de aproximadores de funciones más expresivos (Orr and Dutta, 2023).

En este contexto, las arquitecturas modernas de MARL incorporan redes neuronales profundas para mejorar la escalabilidad y la eficiencia de la coordinación. Entre una de las estrategias más utilizadas se encuentran las Redes Neuronales de Grafos (GNN), que modelan dependencias espaciales y relaciones entre agentes, y los mecanismos de atención, que permiten una comunicación selectiva y adaptativa en función de la tarea (Liu et al., 2024a; Wojtala et al., 2025).

La heterogeneidad robótica introduce complejidades adicionales, ya que los agentes pueden diferir significativamente en capacidades, dinámicas y roles. Para abordar este problema, se han propuesto arquitecturas actor-critic heterogéneas, como HARK y HAPPO (Aguinaco et al., 2023), que permiten entrenar equipos con capacidades asimétricas garantizando la convergencia mediante una factorización adecuada de las funciones de valor (Yu et al., 2023).

El MARL se ha aplicado con éxito a problemas de asignación descentralizada de tareas y a misiones de monitoreo persistente, donde los agentes aprenden a coordinarse en tiempo real bajo restricciones de comunicación y localización (Mishra et al., 2025).

A pesar de estos avances, el MARL presenta limitaciones relevantes en términos de explicabilidad, estabilidad y seguridad certificable, especialmente en escenarios abiertos (Gu et al., 2024). Estas limitaciones han motivado la exploración de enfoques híbridos que combinan aprendizaje con razonamiento explícito, así como la integración de modelos de lenguaje para

introducir planificación semántica y negociación de alto nivel, que se analizan en la siguiente sección.

5. Sistemas Multi-Agentes Robóticos con Lenguaje de Gran Escala

La integración de modelos de Lenguaje de Gran Escala (Large Language Models, LLMs) y de Visión-Lenguaje-Acción (Vision-Language-Action, VLA) ha marcado un cambio de paradigma en la robótica colectiva. Esta sección analiza por qué estas herramientas son indispensables, qué roles desempeñan y cómo se integran en las arquitecturas de MARS.

5.1. Introducción de LLMs en MARS

Más allá de los enfoques basados en optimización y aprendizaje, los LLMs introducen una nueva dimensión en los MARS, como el uso del lenguaje como medio de representación, el razonamiento y la coordinación de alto nivel. Al operar sobre descripciones semánticas en lenguaje natural, los LLMs permiten a los sistemas MARS interpretar objetivos abstractos, gestionar la ambigüedad y razonar sobre misiones no formalizadas matemáticamente (Liu et al., 2024b).

En este contexto, los LLMs emergen como una solución complementaria al actuar como modelos fundacionales entrenados sobre grandes volúmenes de conocimiento lingüístico y estructural, superando a los enfoques tradicionales en escenarios dominados por ambigüedad semántica y toma de decisiones de alto nivel (Liu et al., 2024b).

Por otro lado, Los LLMs aportan capacidades distintivas en sistemas MARS, como el razonamiento de sentido común, que permite inferir relaciones implícitas del entorno físico y social sin programación explícita y adaptar el comportamiento ante cambios (Sha et al., 2023; Liu et al., 2025); la planificación zero-shot, mediante la cual instrucciones en lenguaje natural se descomponen en secuencias de acciones complejas sin entrenamiento específico (Guo et al., 2023); y la generalización transversal, que facilita la transferencia de conocimiento entre distintas morfologías robóticas y entornos no estructurados a través de representaciones latentes compartidas (J. et al., 2024; Ichter et al., 2022).

Estas capacidades permiten abordar problemas de coordinación y planificación que resultan intratables para métodos puramente numéricos o basados exclusivamente en funciones de recompensa, sentando las bases para arquitecturas MARS con inferencia basada en lenguaje de alto nivel.

5.2. Roles de los LLMs en sistemas MARS

En los sistemas robóticos Multi-Agente actuales, los LLMs han evolucionado desde su uso como interfaces lingüísticas hasta su integración como componentes activos dentro del bucle de toma de decisiones, interviniendo en distintos niveles que abarcan desde la deliberación estratégica y la descomposición de tareas hasta la interacción humano-robot.

A nivel deliberativo, permiten la planificación de alto nivel y la descomposición de objetivos complejos en subtareas ejecutables, especialmente en misiones definidas mediante lenguaje natural. Por ejemplo, DART-LLM (Wang et al., 2024) modela dependencias entre subtareas mediante Grafos Acíclicos Dirigidos (DAG), facilitando la planificación a largo horizonte y la

asignación coherente de tareas a equipos heterogéneos, aunque con limitaciones de escalabilidad en grandes flotas.

En la coordinación Multi-Agente, los LLMs habilitan formas de comunicación más flexibles que los protocolos rígidos utilizados en MARL, permitiendo la negociación y el refinamiento contextual de planes. Sistemas como RoCo (Mandi et al., 2023) incorporan comunicación dialéctica basada en lenguaje natural con mecanismos de autorreflexión y corrección iterativa durante la ejecución.

A nivel de ejecución, pueden traducir intenciones en estructuras simbólicas o código ejecutable, como árboles de comportamiento, reduciendo el esfuerzo de ingeniería e integrando niveles cognitivos con sistemas de control físico (Rojas-Ordoñez et al., 2026), aunque la fiabilidad y verificación del código generado siguen siendo aspectos críticos.

En entornos compartidos con humanos, los LLMs desempeñan un papel sociocognitivo al evaluar la seguridad y aceptabilidad de las acciones propuestas, contribuyendo a una navegación social más fiable (Wang et al., 2025). Asimismo, facilitan la interacción humano-robot mediante la interpretación de instrucciones en lenguaje natural, la explicación de decisiones y la adaptación a preferencias humanas, aspectos fundamentales para la seguridad y la aceptación en entornos colaborativos (Liu et al., 2025).

En conjunto, estos roles conforman una arquitectura jerárquica en la que los LLMs aportan capacidades de deliberación y coordinación, mientras que los sistemas de control tradicionales mantienen la ejecución física y las garantías de estabilidad. No obstante, su naturaleza probabilística introduce incertidumbre, latencia y dificultades de verificación, lo que limita su aplicación en sistemas críticos con requisitos de tiempo real.

5.3. Métodos de integración arquitectónica

La incorporación de modelos de lenguaje de gran escala (LLMs) en sistemas robóticos Multi-Agente (MARS) ha generado diversas arquitecturas que difieren en cómo gestionan cognición, coordinación y ejecución. Estas pueden entenderse como un espectro que va desde la centralización hasta la toma de decisiones completamente distribuida.

En un extremo se sitúan las arquitecturas centralizadas con núcleos cognitivos (Figura 2, lado derecho), donde un LLM coordina memoria, herramientas y control global. Propuestas como EMOS (Chen et al., 2024) ilustran este enfoque al integrar información heterogénea con decisiones conscientes del embodiment. Esta centralización mejora la coherencia y es adecuada en sistemas heterogéneos (Mei et al., 2025), pero introduce cuellos de botella, menor escalabilidad y dependencia del nodo central.

Por otro lado, las arquitecturas distribuidas basadas en metaprogramación colaborativa delegan la coordinación en múltiples agentes. Mediante roles y procedimientos definidos por LLMs (Figura 2, lado izquierdo), trabajos como MetaGPT (Hong et al., 2023) mejoran la coordinación y reducen alucinaciones. Este enfoque es más robusto y escalable, aunque complica la coherencia global.

En contraste, los modelos Vision-Language-Action (VLA) como OpenVLA integran percepción y acción en un bucle cerrado, generando comandos directamente desde entradas mul-

timodales (J. et al., 2024; Kim et al., 2025). Esto permite respuestas rápidas y eficientes, pero reduce interpretabilidad y modularidad.

La elección del enfoque depende de los requisitos: la centralización favorece coherencia y control en entornos complejos; la distribución mejora escalabilidad y robustez; y los VLA priorizan reactividad. Por ello, una línea prometedora es el desarrollo de arquitecturas híbridas que combinen núcleos cognitivos con mecanismos distribuidos de coordinación y ejecución.




Figura 2: Arquitectura distribuida vs. centralizada en Sistemas Multi-Agente con Lenguajes de Gran Escala. (Liu et al., 2025)

5.4. Evaluación y puntos de referencia

La evaluación de los MARS basados en Modelos de Lenguaje de Gran Escala ha evolucionado desde métricas tradicionales de rendimiento hacia el análisis de comportamientos colectivos emergentes. Los enfoques recientes no se limitan a medir el éxito de la tarea, sino que incorporan indicadores de la calidad del razonamiento, la coordinación entre agentes, la eficiencia cognitiva, la tasa de éxito y los tiempos de procesamiento.

En este contexto, SwarmBench (Agostinelli et al., 2024) analiza la capacidad de los LLMs para coordinar enjambres bajo restricciones severas de percepción local y comunicación limitada. Por su parte, CLiMBench y Habitat-MAS (Song et al., 2025) evalúan la colaboración de agentes heterogéneos en tareas domésticas de largo alcance, integrando planificación, percepción y manipulación mediante razonamiento basado en lenguaje. Finalmente, la Embodied Agent Interface (Li et al., 2024) proporciona un marco para evaluar capacidades como el razonamiento espacial, el uso de herramientas y la eficiencia en sistemas robóticos basados en modelos fundamentales.

6. Discusión y oportunidades futuras

Los enfoques clásicos, junto con el RL y el MARL, han demostrado una elevada eficacia en la optimización de comportamientos bien definidos y verificables. En contraste, los LLMs introducen capacidades complementarias de deliberación semántica, planificación flexible y comunicación contextual, lo que amplía el alcance operativo de los MARS hacia entornos abiertos. En este sentido, los LLMs no sustituyen a los métodos tradicionales, sino que actúan como una capa cognitiva de alto nivel que coordina y contextualiza políticas de control y habilidades aprendidas.

El análisis realizado sugiere que la arquitectura predominante en sistemas MARS basados en LLMs es híbrida, en la que el modelo lingüístico asume funciones de planificación estratégica, mientras que la ejecución permanece distribuida y

gobernada por métodos algorítmicos clásicos. Esta separación permite aprovechar las capacidades semánticas sin comprometer la estabilidad del sistema, aunque introduce nuevas dependencias en términos de comunicación, latencia y consistencia global.

Desde una perspectiva global, las principales limitaciones identificadas pueden agruparse en tres dimensiones interrelacionadas. En primer lugar, existen desafíos arquitectónicos y de integración, derivados de la ausencia de un consenso claro sobre cómo incorporar capacidades cognitivas probabilísticas en sistemas robóticos físicos, especialmente en arquitecturas híbridas. Esta falta de estandarización se extiende también a los mecanismos de comunicación entre capas centralizadas y ejecución distribuida, lo que dificulta la interoperabilidad y la escalabilidad.

En segundo lugar, se identifican limitaciones asociadas a la seguridad, el tiempo real y la verificabilidad. La naturaleza probabilística de los LLMs, junto con su dependencia de recursos computacionales, introduce incertidumbre en la toma de decisiones y dificulta garantizar propiedades formales de seguridad, especialmente en aplicaciones críticas. Asimismo, el compromiso entre la ejecución remota, con mayor capacidad de razonamiento, y la ejecución local, con menor latencia, sigue siendo un problema abierto.

Finalmente, persisten desafíos relacionados con la validación y la interpretabilidad. La fragmentación entre simuladores de coordinación y plataformas de alta fidelidad física limita la evaluación consistente de estos sistemas, mientras que la falta de marcos que integren aprendizaje Multi-Agente, explicabilidad y trazabilidad del razonamiento dificulta su adopción en entornos reales.

En conjunto, estas limitaciones reflejan una transición incompleta hacia arquitecturas cognitivas plenamente integradas. El progreso futuro en MARS dependerá del desarrollo de sistemas jerárquicos que combinen de forma robusta coordinación algorítmica, aprendizaje y procesamiento basado en lenguaje, con especial énfasis en la escalabilidad, verificabilidad y operación segura en entornos reales.

Agradecimientos

Este trabajo ha sido realizado gracias al apoyo del programa BIKAINTEK 2025 del Gobierno Vasco (Exp. 007-B2/2025) y en colaboración con el proyecto ELKARTEK 2025 SENDOA (Exp. Gobierno Vasco KK-2025/00102).

Referencias

- Agostinelli, S., Ciccone, M., Banfi, J., De Giacomo, G., Iocchi, L., 2024. Benchmarking large language models on swarm intelligence missions. DOI: 10.48550/arXiv.2505.04364
- Aguinaco, I., et al., 2023. A review on reinforcement learning for contact-rich robotic manipulation tasks. IEEE Robotics and Automation Letters. DOI: 10.1016/j.robot.2022.102517
- An, Z., et al., 2023. Multi-robot systems and cooperative object transport: Communications and platforms. IEEE Open Journal of the Computer Society. DOI: 10.1109/OJCS.2023.3238324
- Chakraa, H., Guérin, F., Leclercq, E., Lefebvre, D., 2023. Optimization techniques for Multi-Robot Task Allocation problems: Review on the state-of-the-art. Robotics and Autonomous Systems 168, 104492. DOI: 10.1016/j.robot.2023.104492

- Chen, Y., et al., 2024. Emos: Embodiment-aware heterogeneous multi-robot operating system. arXiv.
DOI: 10.48550/arXiv.2410.22662
- Choi, S., Ryu, K., Ock, J., Mehr, N., 2025. Craft: Coaching reinforcement learning autonomously using foundation models for multi-robot coordination tasks.
DOI: 10.48550/arXiv.2509.14380
- Cuadros Zegarra, E., et al., 2023. Iort-based middleware for heterogeneous multi-robot systems.
DOI: 10.3390/jsan13060087
- Flores, M., et al., 2025. Ros-compatible robotics simulators for industry 4.0 and 5.0. Applied Sciences.
DOI: 10.3390/app15158637
- Galati, G., Primatesta, S., Rizzo, A., 2023. Auction-based task allocation and motion planning for multi-robot systems with human supervision. Journal of Intelligent & Robotic Systems 109 (2), 24.
DOI: 10.1007/s10846-023-01935-x
- Gu, S., et al., 2024. Safe multi-agent reinforcement learning: A survey. arXiv.
DOI: 10.48550/arXiv.2505.17342
- Guo, X., et al., 2023. Smart-llm: Smart multi-agent robot task planning using llms. arXiv.
DOI: 10.48550/arXiv.2309.10062
- Halsted, T., Shorinwa, O., Yu, J., Schwager, M., 2021. A survey of distributed optimization methods for multi-robot systems. arXiv preprint arXiv:2103.12840.
DOI: 10.48550/arXiv.2103.12840
- Harbin, J., et al., 2021. Model-driven simulation-based analysis for multi-robot systems. In: Proceedings of the ACM/IEEE International Conference on Model Driven Engineering Languages and Systems.
DOI: 10.1109/MODELS50736.2021.00040
- Heemels, W., Johansson, K., Tabuada, P., 2013. An introduction to event-triggered and self-triggered control. IEEE Transactions on Automatic Control 58 (12), 3023–3041.
DOI: 10.1109/TAC.2012.2220443
- Hong, S., et al., 2023. Metagtpt: Meta programming for a multi-agent collaborative framework. arXiv.
DOI: 10.48550/arXiv.2308.00352
- Ichter, B., Brohan, A., Chebotar, Y., Finn, C., Hausman, K., Herzog, A., Ho, D., Ibarz, J., Irpan, A., Jang, E., et al., 2022. Do as i can, not as i say: Grounding language in robotic affordances. arXiv preprint arXiv:2204.01691.
DOI: 10.48550/arXiv.2204.01691
- J., K., et al., 2024. Openvla: An open-source vision-language-action model. arXiv.
DOI: 10.48550/arXiv.2406.09246
- Jordán, I. J. C., 2009. Análisis y diseño de sistemas cognitivos para robots autónomos. Archivo Digital UPM (Tesis Doctoral) Director: Ramón Galán López. E.T.S.I. Industriales (UPM).
DOI: 10.20868/UPM.thesis.1818
- Kim, T. W., Zhou, H., Barragan, J. A., Ishida, H., Kazanzides, P., Munawar, A., 2025. Surgical robotics environment in nvidia isaac sim for robot-assisted suturing. In: 2025 International Symposium on Medical Robotics (ISMR). pp. 192–198.
DOI: 10.1109/ISMR67322.2025.11025977
- Kober, J., Bagnell, J. A., Peters, J., 2013. Reinforcement learning in robotics: A survey. The International Journal of Robotics Research 32 (11), 1238–1274.
DOI: 10.1177/0278364913495721
- Li, M., Zhao, S., Wang, Q., Wang, K., Zhou, Y., Srivastava, S., Gokmen, C., Lee, T., Li, L. E., Zhang, R., Liu, W., Liang, P., Fei-Fei, L., Mao, J., Wu, J., 2024. Embodied agent interface: Benchmarking llms for embodied decision making. In: Advances in Neural Information Processing Systems.
DOI: 10.48550/arXiv.2410.07166
- Li, X., Zhang, W., Chen, J., 2023. Data-driven consensus control of discrete-time linear multi-agent systems. Science China Information Sciences 66 (3), 1–14.
DOI: 10.1007/s11432-022-3629-1
- Liu, Y., et al., 2025. Integrating large language models into robotic autonomy: A review. AI.
DOI: 10.3390/ai6070158
- Liu, Z., Zhang, J., Shi, E., Liu, Z., Niyato, D., Ai, B., Shen, X., 2024a. Graph neural network meets multi-agent reinforcement learning: Fundamentals, applications, and future directions. arXiv preprint arXiv:2404.04898.
DOI: 10.48550/arXiv.2404.04898
- Liu, Z., et al., 2024b. Large language models for multi-robot systems: A survey. arXiv.
DOI: 10.48550/arXiv.2502.03814
- Mandi, Z., et al., 2023. Roco: Dialectic multi-robot collaboration with large language models. arXiv.
DOI: 10.48550/arXiv.2307.04738
- Martorell, M., et al., 2024. Coordination of marine multi robot systems with communication constraints. Applied Ocean Research.
DOI: 10.1016/j.apor.2023.103848
- Mei, H., et al., 2025. Aios: Llm agent operating system. arXiv.
DOI: 10.48550/arXiv.2403.16971
- Mishra, M., Poddar, P., Agrawal, R., Chen, J., Tokekar, P., Sujit, P. B., 2025. Multi-agent deep reinforcement learning for persistent monitoring with sensing, communication, and localization constraints. IEEE Transactions on Automation Science and Engineering 22, 2831–2843.
DOI: 10.1109/TASE.2024.3385412
- Orr, J., Dutta, A., 2023. Multi-agent deep reinforcement learning for multi-robot applications: A survey. Sensors.
DOI: 10.3390/s23073625
- Rakhmatillaev, J., Bucinskas, V., Kabulov, N., 2025. An integrative review of control strategies in robotics. Robotic Systems and Applications 5 (2), 50–74.
DOI: 10.21595/rsa.2025.25014
- Rasheed, M., et al., 2022. A review of multi-agent mobile robot systems applications. International Journal of Electrical and Computer Engineering 12 (4), 3517–3529.
DOI: 10.11591/ijece.v12i4.pp3517-3529
- Rojas-Ordoñez, S., Segura, M., Yarza, I., Mendoza, V., Zulueta, E., 2026. Plug-and-play llm knowledge extraction for robot navigation: A fine-tuning-free edge framework. Machine Learning and Knowledge Extraction 8 (2).
DOI: 10.3390/make8020049
- Roldán-Gómez, J. J., De León Rivas, J., Garcia-Aunon, P., Barrientos, A., 2020. Una revisión de los sistemas multi-robot: desafíos actuales para los operadores y nuevos desarrollos de interfaces. Revista Iberoamericana de Automática e Informática industrial 18 (1), 1–16.
DOI: 10.4995/riai.2020.13100
- Sha, H., Mu, Y., Jiang, Y., Zhan, G., Chen, L., Xu, C., Luo, P., Li, S. E., Tomizuka, M., Zhan, W., Ding, M., 2023. Languagempc: Large language models as decision makers for autonomous driving. arXiv arXiv:2310.03026.
DOI: 10.48550/arXiv.2310.03026
- Song, S., Xie, X., Li, Z., Li, Y., Wang, S., Qi, B., 2025. Leveraging adaptive group negotiation for heterogeneous multi-robot collaboration with large language models. IEEE SMC Conference Proceedings.
DOI: 10.1109/SMC58881.2025.11343418
- Souto, T., et al., 2024. Behavior tree capabilities for dynamic multi-robot task allocation with heterogeneous robot teams. arXiv.
DOI: 10.48550/arXiv.2402.02833
- Testa, A., Carnevale, G., Notarstefano, G., 2025. A tutorial on distributed optimization for cooperative robotics: From setups and algorithms to toolboxes and research directions. Proceedings of the IEEE 113 (1), 40–65.
DOI: 10.1109/JPROC.2025.3557698
- Wang, W., et al., 2025. Multi-agent llm actor-critic framework for social robot navigation. arXiv.
DOI: 10.48550/arXiv.2503.09758
- Wang, Y., et al., 2024. Dart-llm: Dependency-aware multi-robot task decomposition and execution using llms. arXiv.
DOI: 10.48550/arXiv.2411.09022
- Wojtala, M., et al., 2025. Mactas: Self-attention-based inter-agent communication in multi-agent reinforcement learning. arXiv.
DOI: 10.48550/arXiv.2508.13661
- Yu, H., et al., 2023. Heterogeneous-agent reinforcement learning. arXiv.
DOI: 10.48550/arXiv.2304.09870
- Zhang, K., Yang, Z., Basar, T., 2021. Multi-agent reinforcement learning: A selective overview. Handbook of Reinforcement Learning and Control.
DOI: 10.1007/978-3-642-14435-6_7
- Zhang, P., He, Y., Wang, Z., Li, S., Liang, Q., 2024. Research on multi-uav obstacle avoidance with optimal consensus control and improved apf. Drones 8 (6), 248.
DOI: 10.3390/drones8060248