

Comparative Analysis of Machine Learning and Deep Learning Techniques in the Development of Mobile Robots: A Systematic Review

Ocaña-Velásquez, Jesús Daniel¹, Dr.^{ID}; Castro-García, José Heiner², Mg.^{ID}; Miranda-Saldaña, Rodolfo Junior³, Mg.^{ID}

^{1,3}Universidad Tecnológica del Perú, Chimbote, Perú, c25777@utp.edu.pe, c20312@utp.edu.pe, e20206@utp.edu.pe

Abstract— The rapid advancement of robotic technologies has driven the development of mobile robots, which are applied in various areas such as industry, logistics, exploration, security, healthcare, and many more. The aim of this research is to analyze and compare machine learning and deep learning techniques in the design and optimization of mobile robots with the purpose of identifying methods that stand out for their accuracy and reliability, thus contributing to the development of more efficient tools and models that increase the effectiveness of robotic systems in various environments. The PRISMA method was used to compile and systematize 65 articles relevant to the study topic. The results show that the development of mobile robots has become a frequent topic of interest for researchers in China and South Korea. In Machine Learning, the most prominent methods are Random Forest (RF) and SVM. In Deep Learning, the most outstanding techniques are CNN and SLAM. It is concluded that Machine Learning focuses on key applications such as navigation and mapping, while Deep Learning deals with complex challenges such as autonomous driving and image processing. Both disciplines complement each other in mobile robotics, where Machine Learning improves functionality and efficiency, and Deep Learning fosters innovation and understanding of the environment, opening opportunities for future research.

Keywords-- Machine Learning, Deep Learning, Mobile Robots, Robot Development.

Análisis Comparativo de Técnicas de Machine Learning y Deep Learning en el Desarrollo de Robots Móviles: Una Revisión Sistemática

Ocaña-Velásquez, Jesús Daniel¹, Dr.; Castro-García, José Heiner², Mg.; Miranda-Saldaña, Rodolfo Junior³, Mg.
^{1,3}Universidad Tecnológica del Perú, Chimbote, Perú, c25777@utp.edu.pe, c20312@utp.edu.pe, e20206@utp.edu.pe

Resumen— El rápido avance de las tecnologías robóticas ha impulsado el desarrollo de robots móviles, que se aplican en diversas áreas como la industria, la logística, la exploración, la seguridad, la salud y muchas más. El objetivo de esta investigación es analizar y comparar técnicas de machine learning y deep learning en el diseño y optimización de robots móviles con el propósito de identificar métodos que se destaque por su precisión y fiabilidad, contribuyendo así al desarrollo de herramientas y modelos más eficientes que incrementen la eficacia de los sistemas robóticos en diversos entornos. Se utilizó el método PRISMA para compilar y sistematizar 65 artículos pertinentes al tema de estudio. Los resultados muestran que el desarrollo de robots móviles se ha convertido en temas de interés frecuente para los investigadores en China y Corea del Sur. En Machine Learning, los métodos más destacados son el Bosque Aleatorio (RF) y SVM. En Deep Learning, las técnicas más sobresalientes son las CNN y el SLAM. Se concluye que Machine Learning se enfoca en aplicaciones clave como navegación y mapeo, mientras que el Deep Learning se ocupa de retos complejos como la conducción autónoma y el procesamiento de imágenes. Ambas disciplinas se complementan en la robótica móvil, donde Machine Learning mejora funcionalidad y eficiencia, y Deep Learning fomenta la innovación y la comprensión del entorno, abriendo oportunidades para futuras investigaciones.

Palabras clave-- Machine Learning, Deep Learning, Robots Móviles, Desarrollo de Robots.

I. INTRODUCCIÓN

En las últimas décadas, el crecimiento acelerado de las tecnologías robóticas ha propiciado el desarrollo de robots móviles que han cambiado de manera significativa varias industrias, incluyendo la manufactura, la logística y la atención sanitaria [1], [2], [3]. Los robots móviles, equipados con sensores y algoritmos sofisticados, son capaces de operar de manera autónoma en entornos complejos. Esto les permite ofrecer soluciones eficientes a desafíos que anteriormente requerían la intervención humana [4], [5], [6].

Los algoritmos de Machine Learning son conjuntos de reglas y técnicas que permiten a los modelos aprender de los datos y realizar predicciones. Estos algoritmos se clasifican en tres categorías principales según el tipo de aprendizaje que emplean: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo [7], [8]. Existen varios algoritmos de machine learning esenciales para el desarrollo de robots móviles. En Aprendizaje Supervisado, destacan la Regresión

Lineal, Árboles de Decisión, Máquinas de Soporte Vectorial (SVM) y Redes Neurales. En Aprendizaje No Supervisado, son importantes K-medias, DBSCAN y XGBoost para identificar patrones. En Aprendizaje por Refuerzo, se utilizan Q-Learning, Redes Neurales Profundas, Aprendizaje por Refuerzo Profundo (DRL) y Proximal Policy Optimization (PPO) para la toma de decisiones en entornos dinámicos [9], [10], [11], [12].

Los algoritmos de Deep Learning en robótica móvil utilizan redes neuronales profundas para que los robots interactúen de forma autónoma con su entorno, mejorando su navegación, reconocimiento de objetos y toma de decisiones en tiempo real, lo que optimiza su autonomía y funcionalidad en diversas aplicaciones [13], [14]. Los algoritmos de Deep Learning son esenciales para el avance de los robots móviles. Destacan las Redes Neuronales Convolucionales (CNN) para el procesamiento de imágenes, las Redes Neuronales Recurrentes (RNN) para el análisis de secuencias, las Redes Generativas Antagónicas (GANs) para generar nuevos datos y las Redes de Memoria a Corto y Largo Plazo (LSTM) para manejar dependencias a largo plazo en datos secuenciales. Estos algoritmos son fundamentales en el desarrollo de tecnologías robóticas avanzadas [15], [16], [17].

La investigación evalúa la efectividad de técnicas de machine learning y deep learning, destacando sus métodos, ventajas y desventajas. Los resultados permitirán tomar decisiones informadas en desarrollos futuros y avanzarán el conocimiento en robótica inteligente, sirviendo de base para investigaciones posteriores.

La investigación evalúa la eficacia de enfoques de inteligencia artificial en la navegación, percepción y toma de decisiones de robots móviles, comparando el Deep Learning con técnicas tradicionales de Machine Learning en entornos complejos. El propósito es examinar los beneficios y las restricciones de las dos técnicas para orientar a investigadores y desarrolladores en sus elecciones tecnológicas.

El objetivo de esta investigación es analizar y comparar técnicas de machine learning y deep learning en el diseño y optimización de robots móviles, identificando métodos destacados por su precisión y fiabilidad. Se busca contribuir al desarrollo de herramientas y modelos más eficientes que mejoren la eficacia de los sistemas robóticos en diversos entornos.

Este documento se divide en cinco secciones: la primera revisa estudios previos, la segunda describe la metodología utilizada, la tercera presenta los resultados, la cuarta los hallazgos y, finalmente, se presentan las conclusiones.

II. TRABAJO RELACIONADO

Resumir artículos científicos en robótica e inteligencia artificial es crucial para contextualizar la investigación. Permite identificar vacíos en la literatura, justificar la necesidad del estudio y comparar técnicas. Además, valida resultados, muestra la evolución de metodologías y refuerza argumentos a favor de enfoques específicos, enriqueciendo la investigación y avanzando el conocimiento en el campo.

El estudio [18] busca desarrollar e implementar técnicas de aprendizaje automático, como lógica difusa y redes neuronales, incluyendo enfoques neurodifusos. Los hallazgos son relevantes para mejorar el control en robótica, la identificación de patrones y la simulación de robots. Los autores concluyen que el software es efectivo para diseñar sistemas de control robótico y entrenar redes neuronales convolucionales para el reconocimiento de objetos a partir de datos de sensores de video.

El estudio [19] cuyo objetivo es integrar modelos basados en CNN para mejorar la eficiencia y precisión computacional en la resolución del problema de estática inversa. Los resultados subrayan los significativos beneficios que se obtienen al combinar la CNN profunda con los modelos de Formulación de coordenadas nodales absolutas (ANCF), facilitando así el desarrollo de un modelado estático avanzado en la robótica de materiales blandos. Concluyeron que esta investigación propone un enfoque de modelado fundamentado en datos, utilizando una red neuronal convolucional profunda (CNN), la cual está destinada a ofrecer soluciones en tiempo real para la estática inversa de robots de continuo blando, en el contexto de la formulación de coordenadas nodales absolutas (ANCF).

El estudio [20] desarrolla y evalúa un modelo de clasificación de imágenes en tiempo real con alta precisión, superando investigaciones previas. Los autores concluyen que su método de navegación visual es eficiente y accesible para la orientación de robots móviles en interiores, eliminando la necesidad de mapas y datos de ubicación, lo que amplía las aplicaciones en servicios automatizados.

III. METODOLOGÍA

En el estudio presentado se emplea el método PRISMA, que facilita la documentación clara y precisa de los artículos vinculados a este tema.

A. Preguntas de Investigación

Se formularon cuatro preguntas de investigación empleando el modelo PICO.

RQ1: ¿Cuáles son las principales diferencias entre las características de Machine Learning y Deep Learning en el desarrollo de robots móviles?

RQ2: ¿Cuáles son las principales aplicaciones de robots móviles que utilizan técnicas de Machine Learning y Deep Learning?

RQ3: ¿Cuáles son los métodos utilizados en Machine Learning y Deep Learning en el desarrollo de robots móviles?

RQ4: ¿Cómo contribuye la integración de técnicas de Machine Learning y Deep Learning en el desarrollo de robots móviles?

B. Estrategia de búsqueda

El estudio se lleva a cabo utilizando una búsqueda específica y la aplicación de filtros en bases de datos como Scopus, ScienceDirect, IEEE Xplore, EBSCOhost y Web of Science, con el fin de encontrar artículos pertinentes. Posteriormente, se aplican criterios de inclusión y exclusión, que se describen en la tabla 1 de acuerdo al método PRISMA, para decidir los artículos seleccionados para su análisis.

La cadena de búsqueda empleada para localizar artículos que contengan tanto el título como los términos clave de la investigación es la siguiente:

("mobile robot" OR "mobile robots") AND ("machine learning" OR "machine learning algorithms" OR "deep learning" OR "Deep learning algorithms") AND ("development" OR "Types" OR "applications") OR ("advantages" OR "disadvantages")

C. Criterios de inclusión y exclusión

Los criterios de inclusión y exclusión de esta revisión sistemática se detallan en la Tabla 1.

TABLA I
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Criterios		
	I01	Artículos relacionados con Machine Learning o Deep Learning en el desarrollo de robots móviles.
Inclusión	I02	Artículos que mencionan las aplicaciones de robots móviles utilizando Machine Learning o Deep Learning
	I03	Artículos en inglés
	I04	Artículos de los últimos 4 años (2021 -2024).
	E01	Artículos que no guardan relación con el tema de investigación
Exclusión	E02	Artículos que no tengan Open Access
	E03	Artículos ajenos al Machine Learning o Deep Learning en el desarrollo de robots móviles.

Se aplicó el método PRISMA en tres fases para seleccionar artículos para esta investigación. En la primera fase, se identificaron 3,382 artículos de cinco bases de datos, de los cuales se eliminaron 356 duplicados, quedando 3,026. Luego, se filtraron para incluir solo aquellos de acceso abierto,

reduciéndose a 1,933. Tras un análisis exhaustivo, se desestimaron 521 artículos que no cumplían con los criterios de inclusión, dejando 572 para evaluación. Finalmente, se excluyeron 507 artículos no relevantes, seleccionando un total de 65 artículos para la investigación.

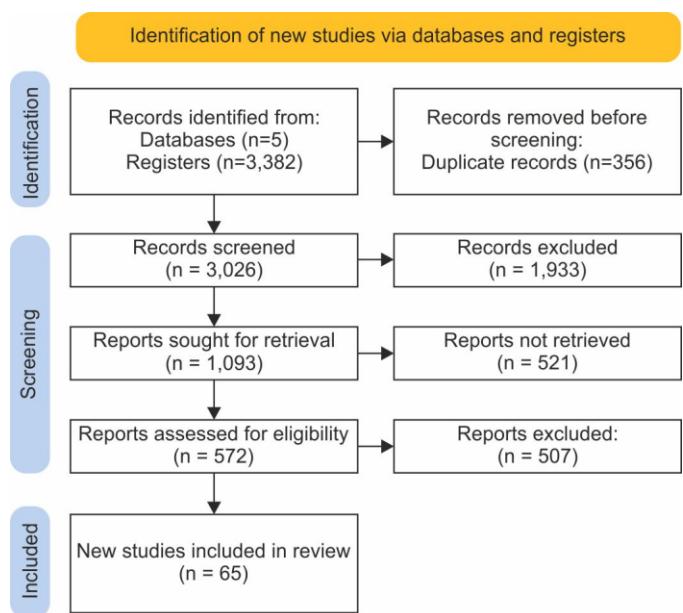


Fig. 1 Selección de artículos científicos según método PRISMA

IV. RESULTADOS

Se presenta un análisis bibliométrico de 65 artículos que cumplen con los criterios de inclusión definidos.

A. Análisis bibliométrico

El análisis bibliométrico es una técnica cuantitativa que emplea métodos matemáticos, estadísticos y minería de datos para identificar tendencias en un área de investigación específica. Utilizando VOSViewer, se llevó a cabo un análisis exhaustivo de la información relacionada con diversas investigaciones, lo que permitió la generación de redes de palabras clave y mapas de visualización. Estas herramientas facilitan una interpretación más clara y efectiva de los datos, promoviendo una comprensión profunda de las dinámicas en el campo estudiado.

Se llevó a cabo un análisis de 236 palabras clave, estableciendo un umbral mínimo de una aparición, lo que resultó en la identificación de 14 terminologías clave, como se muestra en la Figura 2. En el mapa de la red, los nodos más prominentes representan los siguientes grupos: "Machine Learning" (rojo), "Deep Learning" (celeste), "Mobile Robots" (verde) y "Artificial Intelligence" (dorado).

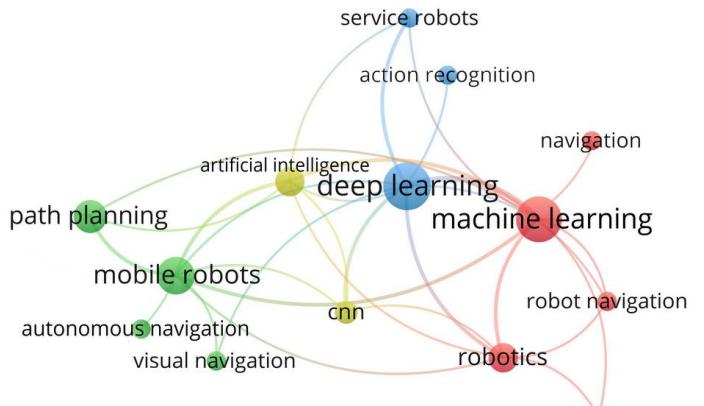


Fig. 2 Mapa bibliométrico de las relaciones entre palabras clave

El análisis del mapa de la red en la Figura 2 revela 14 palabras clave interconectadas. El nodo "Machine Learning" se asocia con "robotics", "robot navigation", "neural network" y "navigation". "Deep Learning" se vincula con "action recognition" y "service robots". Por otro lado, "mobile robots" está relacionado con "path planning", "autonomous navigation" y "visual navigation". Finalmente, "artificial intelligence" conecta con "cnn".

El nodo "Deep Learning" se sitúa en el centro de la red, vinculado a "Machine Learning", "mobile robots" y "artificial intelligence", lo que resalta el creciente interés en el desarrollo de robots móviles utilizando estas tecnologías.

B. Análisis de manuscritos

Se llevó a cabo un análisis detallado en varias bases de datos, Se identificaron 3,382 estudios iniciales, de los cuales se eliminaron 356 duplicados. Tras aplicar los criterios de inclusión y exclusión, se seleccionaron 65 estudios relevantes, como se muestra en la Figura 3.

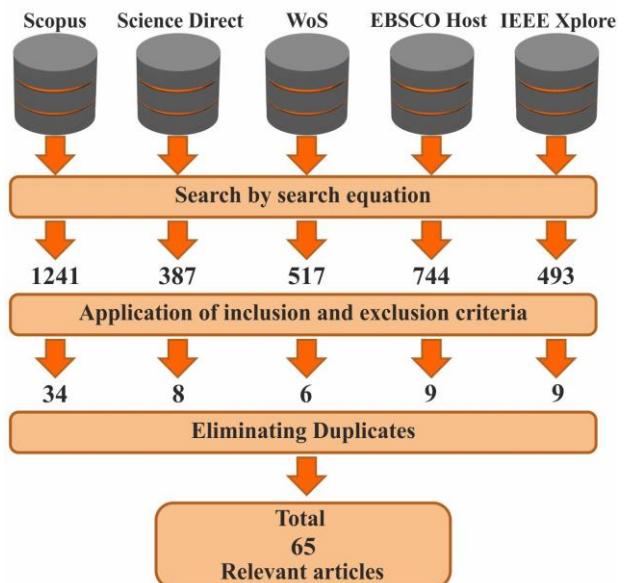


Fig. 3 Resultados obtenidos en la búsqueda

La Figura 4 muestra una representación pormenorizada del porcentaje de aporte informativo de diferentes bases de datos, donde Scopus se destaca al encabezar con un notable 48% del total de contribuciones. A continuación, Web of Science ocupa el segundo lugar con un 15%, seguido por Science Direct con un 14%. IEEE Xplore representa un 12% y EBSCO Host un 11%. Esta distribución porcentual no solo resalta la importancia de cada base de datos, sino que también refleja las preferencias y tendencias actuales en el acceso a este campo de estudio.

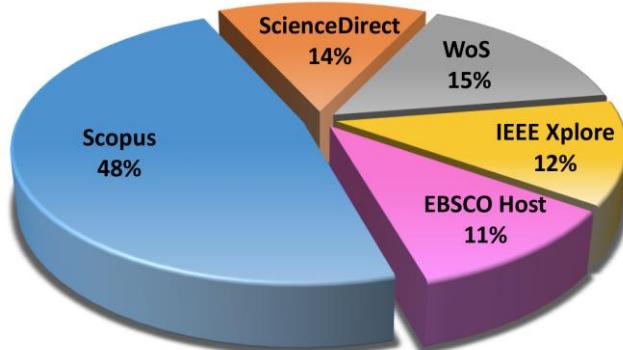


Fig. 4 Gráfico de resultados obtenidos en la búsqueda

El estudio analiza la contabilización anual de artículos publicados entre 2021 y 2024, seleccionados por criterios de inclusión. La Figura 5 muestra un gráfico de barras ilustra la cantidad y el porcentaje de artículos en la revisión sistemática por año. Se aprecia un notable aumento en la producción literaria, lo que evidencia un creciente interés en esta área de investigación. En 2023, se registraron 20 artículos (30.8%), mientras que en 2024 se alcanzó un máximo de 25 artículos (38.5%).

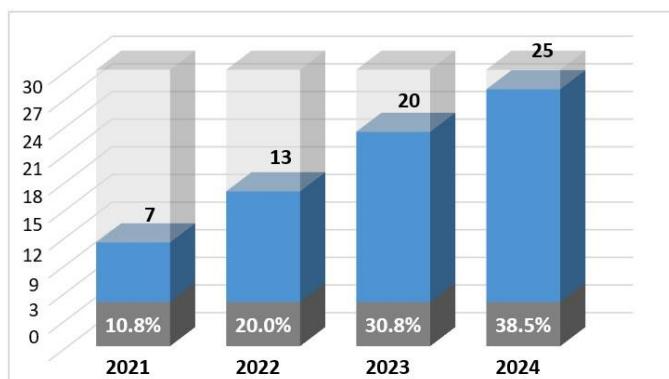


Fig. 5 Porcentajes de cantidad de artículos por año

La Figura 6 muestra el número de artículos publicados anualmente en varias bases de datos. En 2024, se observó un aumento en las publicaciones, destacando Scopus con 12 artículos, seguido de ScienceDirect y Web of Science con 4 cada uno, IEEE Xplore con 3, y EBSCO Host con 2 artículos.

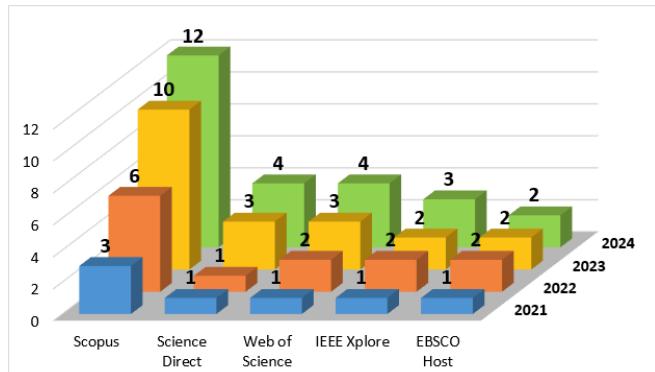


Fig. 6 Artículos por año y base de datos

La Figura 7 muestra la distribución de artículos publicados por país, destacando a China como el principal contribuyente con 17 artículos, seguido por Corea del Sur con 7, Estados Unidos e India con 6 cada uno. España y Malasia aportan 4 artículos, mientras que Inglaterra y Turquía tienen 3. Arabia Saudita, Polonia, Italia, Alemania y Japón contribuyen con 2 artículos cada uno. Finalmente, Francia, Rumania, Nueva Zelanda, Noruega e Irak tienen la menor producción, con un solo artículo publicado cada uno.



Fig. 7 Número de artículos publicados por país

V. DISCUSIÓN

Se llevó a cabo un exhaustivo proceso de selección y análisis de la literatura. A partir de los artículos seleccionados, no solo se identificaron tendencias y carencias en la investigación, sino que también se formularon las preguntas de investigación que guían este estudio. A través de esta revisión, nuestra meta es profundizar en la comprensión de la aplicación de estas tecnologías avanzadas en el desarrollo de robots móviles.

RQ1: ¿Cuáles son las principales diferencias entre las características de Machine Learning y Deep Learning en el desarrollo de robots móviles?

La Tabla 2 presenta un resumen de las diferencias esenciales entre Machine Learning y Deep Learning en el desarrollo de robots móviles. En el caso de Machine Learning, se destaca que estos robots adquieren la capacidad de realizar tareas específicas mediante el análisis de datos, seguido de la

navegación basada en mapas predefinidos, lo que les permite moverse de manera eficiente en entornos conocidos y depender de información previa para ejecutar sus tareas. En contraste, el Deep Learning se distingue por su capacidad de navegación autónoma en entornos desconocidos y lo hace en tiempo real. Esto permite a los robots navegar de forma independiente en entornos dinámicos y complejos, aprendiendo y adaptándose a nuevas situaciones sin depender de mapas predefinidos. Esta capacidad es crucial en aplicaciones como la exploración de áreas no mapeadas y las operaciones de rescate.

TABLA II
DIFERENCIAS ENTRE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Características	Referencia
Machine Learning	Aprenden a realizar tareas específicas de los datos	[21], [22], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34], [35], [36], [37].
	Clasificación de objetos	[21], [24], [28], [34], [37], [38].
	Navegación basada en mapas predefinidos	[21], [22], [23], [24], [26], [27], [28], [30], [31], [33], [34], [35], [37], [38], [39].
	Decisiones para evitar obstáculos basadas en reglas	[22], [23], [40], [37], [38], [39], [41], [42].
Deep Learning	Automáticamente aprende de los datos	[43], [44], [45], [46], [47], [48], [49], [50], [51], [52], [53], [54].
	Reconocimiento de patrones	[43], [55], [56], [57], [58].
	Navegación autónoma en entornos desconocidos	[43], [44], [45], [48], [59], [50], [51], [52], [53], [54], [56], [57], [58], [60], [61], [62], [63], [64], [65], [66], [67], [68], [69], [70], [71], [72], [73].
	Navegación en tiempo real	[29], [42], [44], [45], [48], [49], [50], [51], [52], [53], [54], [55], [57], [58], [60], [61], [62], [63], [64], [66], [67], [69], [70], [74], [75], [76].

RQ2: ¿Cuáles son las principales aplicaciones de robots móviles que utilizan técnicas de Machine Learning y Deep Learning?

La Tabla 4 proporciona una visión exhaustiva sobre las diversas aplicaciones de los robots móviles. Los estudios revisados subrayan que la aplicación más relevante en el ámbito del Machine Learning es la navegación y el mapeo, fundamentales para el progreso tecnológico y la mejora de procesos en varias industrias, seguida por el desarrollo de sistemas de transporte autónomos, que perciben su entorno, toman decisiones y navegan de manera efectiva. En cambio, Deep Learning se destaca por la conducción autónoma y en el uso de cámaras para la percepción visual, lo que sugiere una tendencia hacia el desarrollo de sistemas más complejos y un

procesamiento de datos avanzado. Esto impulsa innovaciones en la interacción y comprensión del entorno, con importantes implicaciones para futuras investigaciones en robótica móvil.

TABLA III
APLICACIONES DE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Aplicaciones	Referencia
Machine Learning	Navegación y Mapeo	[21], [22], [23], [24], [26], [27], [28], [30], [31], [33], [34], [35], [37], [38], [39], [41], [40], [77].
	Reconocimiento de objetos	[24], [30], [32], [37].
	Percepción del Entorno	[21], [22], [24], [25], [30], [31], [33], [34], [35], [36], [37], [38], [39].
	Transporte Autónomos	[21], [23], [25], [26], [27], [30], [31], [34], [35], [36], [37], [39], [41], [40].
	Agricultura	[23], [26], [36], [39].
	Exploración y búsqueda	[30], [38], [39].
	Usa cámaras	[33], [34], [36], [40], [46].
	Robots de servicio	[24], [27], [30], [77].
Deep Learning	Áreas industriales	[27], [30], [31], [34], [35], [37], [39], [77].
	Conducción autónoma	[29], [42], [43], [44], [45], [50], [51], [52], [53], [54], [57], [58], [60], [61], [62], [63], [64], [67], [69], [59], [70], [71], [72], [73], [74], [76], [78], [79].
	Detección de Objetos	[32], [45], [50], [51], [54], [55], [56], [57], [58], [60], [61], [62], [63], [67], [70], [74], [75], [76], [79], [80].
	Con cámaras	[32], [46], [48], [51], [52], [53], [54], [56], [57], [58], [62], [63], [64], [67], [69], [70], [71], [81], [74], [75], [76], [79], [82].
	Exploración	[45], [50], [52], [63], [70], [73], [81], [79].
	Drones	[45], [48].
	Seguridad	[42], [45], [48], [52], [79], [83].
	Agricultura	[48], [57], [61].
	Acuáticos	[42].
	Rescate	[50], [81], [79].
	educativos	[71], [80].
	Servicio doméstico	[32], [55], [66], [76], [82].
	Delivery	[53], [58].
	Áreas industriales	[51], [69], [59].

RQ3: ¿Cuáles son los métodos utilizados en Machine Learning y Deep Learning en el desarrollo de robots móviles?

La Tabla 3 presenta un análisis de los métodos de Machine Learning y Deep Learning. En el ámbito de Machine Learning, el método más destacado es Random Forest (RF), es una herramienta poderosa para potenciar la percepción y la

toma de decisiones, facilitando un comportamiento más inteligente y autónomo en entornos dinámicos, seguido por Support Vector Machine (SVM) que Permite crear mapas del entorno y determinar simultáneamente la propia ubicación en ellos. Por otro lado, En el ámbito del Deep Learning, las Redes Neuronales Convolucionales (CNN) son destacadas por su eficacia en el procesamiento de imágenes y reconocimiento de patrones, lo que ha facilitado su adopción en aplicaciones de visión por computadora. Además, la creciente relevancia de Simultaneous Localization and Mapping (SLAM) como un segundo modelo relevante, que permite que un robot móvil genere un mapa de su entorno mientras se localiza en él en tiempo real. La integración de ambos modelos podría fomentar innovaciones en robótica y navegación autónoma, resaltando la importancia de investigar su complementariedad y aplicaciones en entornos complejos

TABLA III
TIPO DE MÉTODOS DE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Métodos	Referencia
Machine Learning	Linear Regression	[22], [33], [35], [40].
	Decision Trees	[26], [29], [35], [36], [40], [82], [75].
	Naive Bayes	[28], [36], [67], [75].
	Random Forest RF	[26], [28], [29], [31], [33], [35], [42], [40], [67], [82].
	KNN	[23], [26], [36], [40].
	XGBoost	[31], [33].
	SVR	[35], [42].
	SVM	[23], [26], [28], [29], [36], [41], [40], [57], [75].
	Q-Learning	[38], [34], [39].
	SLAM	[21], [24], [27], [30], [57], [59], [77].
Deep Learning	CNN	[28], [31], [34], [40], [48], [50], [54], [57], [58], [67], [69], [70], [71], [83], [80], [82], [84].
	RCNN	[51], [58], [61], [67], [76].
	RNN	[42], [55], [83].
	DNN	[40], [45], [49], [57], [68], [72], [82].
	LSTM	[29], [33], [42], [40], [45], [55], [56], [75].
	YOLOv4	[51], [57], [61], [63], [76].
	YOLOv5	[46], [54], [58], [74].
	DRL	[43], [52], [65], [70].
	SLAM	[40], [53], [60], [64], [66], [69], [59], [70], [78].
	DWA	[49], [54], [57], [63], [65], [66].
	ICP	[57], [69], [59].
	DQN	[34], [40], [47], [49], [84].
	MP-DQN	[70], [81].
	A*	[45], [57], [79].

RQ4: ¿Cómo contribuye la integración de técnicas de Machine Learning y Deep Learning en el desarrollo de robots móviles?

La Tabla 5 resalta las Redes Neuronales Convolucionales (CNN), que permiten a los robots identificar su entorno, reconocer terrenos, evitar obstáculos y detectar víctimas en desastres, así como brindar atención al paciente y servicios a domicilio. Estas innovaciones mejoran las capacidades de los robots móviles y amplían su uso en diversas áreas, mostrando un impacto positivo en la sociedad actual. La investigación en navegación, reconocimiento de terreno y evitación de obstáculos resalta la relevancia de combinar Machine Learning y Deep Learning para mejorar la precisión y eficiencia de estos sistemas. Se emplean algoritmos como Árbol de Decisión y Support Vector Machines (SVM) para clasificar datos en entornos complejos, mientras que técnicas de Deep Learning, como Redes Neuronales Convolucionales (CNN) y SLAM, se utilizan para tareas avanzadas como el reconocimiento de imágenes y la localización en tiempo real. Esta integración optimiza la toma de decisiones y aumenta la adaptabilidad y robustez de los sistemas autónomos ante cambios ambientales, representando un avance significativo en estas tecnologías.

TABLA V
LA INTEGRACIÓN DE TÉCNICAS DE MACHINE LEARNING Y DEEP LEARNING

Métodos		Método más eficiente	Aplicación	Ref.
Machine Learning	Deep Learning			
Random Forest, Naive Bayes, Neural net, SVM, LDA.	CNN, HOG, SLAM, gist	CNN, SVM y LDA	Localización del entorno más precisos	[28]
SVM, Decision Trees, Random Forest,	LSTM, CNN-LSTM	LSTM	Entornos exteriores y terrenos irregulares	[29]
Random Forest, SVM, XGBoost	CNN, VGG16	Random Forest, XGBoost, VGG16	Entornos hostiles	[31]
Linear regression, Decision tres, SVR.	CNN, LeNet-5, AlexNet y VGG16	Linear regression, CNN	Servicio a domicilio	[32]
Linear Regression, Random Forest, XGBoost	LSTM, RNN.	XGBoost, LSTM	Posición de los robots móviles	[33]
Linear regression, Decision tres, Random Forest, KNN, GPR, SVM, DBSCAN	ANN, CNN, LSTM, DNN, SLAM, DQN	Decision tres, SVM, CNN, SLAM	Navegación, reconocimiento de terreno y evitación de obstáculos	[40]

SVR, Random Forest, filtro de Kalman (KF), GPR.	RNN, LSTM, GRU, BiLSTM, Bi-GRU	Bi-GRU, GRU, SVR.	Predicción de trayectorias	[42]
Decision Trees, Random Forest, libSVM	CNN, RCNN, YOLOv5, GNN.	Random Forest, GNN	Detección y el seguimiento de personas	[67]
Decision Trees, Árbol de Modelo Lineal (LMT), LibSVM, SVM	CNN, LSTM, ResNet-50,	Decision Trees, CNN y ResNet50	Detección de víctimas de desastres	[75]
Decision Trees, Random Forest.	CNN, DNN.	Decision Trees, CNN	Atención al paciente	[82]

VI. CONCLUSIONES

Este estudio indica que Machine Learning permite a los robots móviles realizar tareas específicas y navegar eficientemente en entornos conocidos mediante el análisis de datos y mapas predefinidos, el Deep Learning ofrece una ventaja significativa al dotar a estos robots de la capacidad de navegar de manera autónoma y en tiempo real en entornos desconocidos, adaptándose y aprendiendo de nuevas situaciones, lo que resulta esencial para aplicaciones en áreas no mapeadas y en misiones de rescate.

Mientras que Machine Learning se centra en aplicaciones esenciales como la navegación y el mapeo, que son cruciales para el avance de la tecnología en diversos sectores, el Deep Learning se distingue por su capacidad para abordar desafíos más complejos, como la conducción autónoma y el procesamiento de imágenes, lo que permite una percepción visual más sofisticada. Esta diferenciación entre ambas disciplinas resalta un enfoque complementario en la robótica móvil, donde el Machine Learning establece las bases para la funcionalidad y eficiencia, mientras que el Deep Learning impulsa la innovación y la comprensión del entorno, sugiriendo direcciones prometedoras para futuras investigaciones en este campo.

Tanto Machine Learning como Deep Learning ofrecen herramientas valiosas y complementarias para abordar desafíos en robótica y navegación autónoma, evidenciando sus respectivas fortalezas; mientras que el Random Forest y Support Vector Machine en Machine Learning son efectivos para la toma de decisiones y la creación de mapas del entorno, las Redes Neuronales Convolucionales y SLAM en Deep Learning sobresalen en el procesamiento de imágenes y la localización simultánea, respectivamente. La combinación de estos métodos podría potenciar aún más las capacidades de percepción y autonomía en entornos dinámicos, sugiriendo un camino prometedor hacia innovaciones significativas en el campo.

La importancia de la sinergia entre Machine Learning y Deep Learning en la mejora de la funcionalidad de los robots móviles, destacando cómo las técnicas de ML, como los algoritmos de Árbol de Decisión y Support Vector Machines,

se complementan con las capacidades avanzadas de DL, como las Redes Neuronales Convolucionales (CNN), para abordar desafíos complejos en entornos dinámicos. Esta combinación no solo optimiza la precisión y eficiencia en tareas como la navegación y el reconocimiento de imágenes, sino que también potencia la adaptabilidad y robustez de los sistemas autónomos, lo que se traduce en un impacto positivo en aplicaciones prácticas relevantes, desde la atención médica hasta la respuesta a desastres.

REFERENCIAS

- [1] Y. Fu and Q. Zhou, "Analysis and application research of mobile robot navigation related technologies," *Appl. Comput. Eng.*, vol. 9, no. 1, pp. 92–96, Sep. 2023, doi: 10.54254/2755-2721/9/20230055.
- [2] H. Li, J. Liu, C. Lyu, D. Liu, and Y. Liu, "Design and Implementation of Omnidirectional Mobile Robot for Materials Handling among Multiple Workstations in Manufacturing Factories," *Electronics*, vol. 12, no. 22, Nov. 2023, doi: 10.3390/ELECTRONICS12224693.
- [3] A. Neaz, S. Lee, and K. Nam, "Design and Implementation of an Integrated Control System for Omnidirectional Mobile Robots in Industrial Logistics," *Sensors (Basel)*, vol. 23, no. 6, Mar. 2023, doi: 10.3390/S23063184.
- [4] S. Zhao and S. H. Hwang, "ROS-Based Autonomous Navigation Robot Platform with Stepping Motor," *Sensors (Basel)*, vol. 23, no. 7, Apr. 2023, doi: 10.3390/S23073648.
- [5] A. Oultiligh, H. Ayad, A. El Kari, M. Mjahed, and N. El Gmili, "A novel improved elephant herding optimization for path planning of a mobile robot," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 1, pp. 206–217, Feb. 2024, doi: 10.11591/ijece.v14i1.pp206-217.
- [6] H. Z. Khaleel and B. K. Oleiwi, "Ultrasonic sensor decision-making algorithm for mobile robot motion in maze environment," *Bull. Electr. Eng. Informatics*, vol. 13, no. 1, pp. 109–116, Feb. 2024, doi: 10.11591/EEI.V13I1.6560.
- [7] H. K. Albahadily, M. Q. Mohammed, and A. K. Mohammed, "A Practical Guide of Machine Learning Algorithms and Applications," *Int. J. Appl. Inf. Syst.*, vol. 12, no. 40, pp. 8–13, Apr. 2023, doi: 10.5120/IJAIS2023451938.
- [8] M. E. ÇİMEN, Z. GARİP, Y. YALÇIN, M. KUTLU, and A. F. BOZ, "Self Adaptive Methods for Learning Rate Parameter of Q-Learning Algorithm," *J. Intell. Syst.*, vol. 6, no. 2, pp. 191–198, Sep. 2023, doi: 10.38016/JISTA.1250782.
- [9] M. M. Hemal *et al.*, "An Integrated Smart Pond Water Quality Monitoring and Fish Farming Recommendation Aquabot System," *Sensors*, vol. 24, no. 11, Jun. 2024, doi: 10.3390/S24113682.
- [10] H. F. Zabar and Y. Alaiwi, "Application of Efficient Mobile Robot Navigation through Machine Learning Technique," *AIP Conf. Proc.*, vol. 3092, no. 1, Mar. 2024, doi: 10.1063/5.0199704.
- [11] I. Stančić, J. Musić, T. Grujić, M. K. Vasić, and M. Bonković, "Comparison and Evaluation of Machine Learning-Based Classification of Hand Gestures Captured by Inertial Sensors," *Computation*, vol. 10, no. 9, Sep. 2022, doi: 10.3390/COMPUTATION10090159.
- [12] Y. Yan *et al.*, "The Navigation of Home Service Robot Based on Deep Learning and Machine Learning," *J. Robot.*, vol. 2024, 2024, doi: 10.1155/2024/5928227.
- [13] D. Han, B. Mulyana, V. Stankovic, and S. Cheng, "A Survey on Deep Reinforcement Learning Algorithms for Robotic Manipulation," *Sensors (Basel)*, vol. 23, no. 7, Apr. 2023, doi: 10.3390/S23073762.
- [14] P. A. W. Santiry, I. K. Swardika, D. A. I. C. Dewi, and I. B. K. Sugirianta, "Intra-class deep learning object detection on embedded computer system," *IAES Int. J. Artif. Intell.*, vol. 13, no. 1, pp. 430–439, Mar. 2024, doi: 10.11591/IJAI.V13.I1.PP430-439.
- [15] R. Sota, T. Nishimura, and T. Horiuchi, "A STUDY ON OPTIMIZATION OF HYPER-PARAMETERS IN DEEP REINFORCEMENT LEARNING BY BAYESIAN OPTIMIZATION," *ICIC Express Lett. Part B Appl.*, vol. 15, no. 7, pp. 723–731, Jul. 2024, doi: 10.24507/ICICELB.15.07.723.

- [16] S. M. H. Jafri and R. Kala, "Dynamic Head-on Robot Collision Avoidance Using LSTM," *Neural Process. Lett.*, vol. 55, no. 2, pp. 1173–1208, Apr. 2023, doi: 10.1007/S11063-022-10932-4.
- [17] L. Zholshiyeva *et al.*, "Human-machine interactions based on hand gesture recognition using deep learning methods," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 1, pp. 741–748, Feb. 2024, doi: 10.11591/JJECE.V14I1.PP741-748.
- [18] Y. Kondratenko, I. Atamanyuk, I. Sidenko, G. Kondratenko, and S. Sichevskyi, "Machine Learning Techniques for Increasing Efficiency of the Robot's Sensor and Control Information Processing," *Sensors*, vol. 22, no. 3, Feb. 2022, doi: 10.3390/S22031062.
- [19] H. El-Hussieny, I. A. Hameed, and A. A. Nada, "Deep CNN-Based Static Modeling of Soft Robots Utilizing Absolute Nodal Coordinate Formulation," *Biomimetics*, vol. 8, no. 8, p. 611, Dec. 2023, doi: 10.3390/biomimetics8080611.
- [20] T. Ran, L. Yuan, and J. B. Zhang, "Scene perception based visual navigation of mobile robot in indoor environment," *ISA Trans.*, vol. 109, pp. 389–400, Mar. 2021, doi: 10.1016/j.isatra.2020.10.023.
- [21] T. Takebayashi, R. Miyagisuku, and K. Ozaki, "Development of magnetic-based navigation by constructing maps using machine learning for autonomous mobile robots in real environments," *Sensors*, vol. 21, no. 12, Jun. 2021, doi: 10.3390/S21123972.
- [22] S. Das and S. K. Mishra, "A Machine Learning approach for collision avoidance and path planning of mobile robot under dense and cluttered environments," *Comput. Electr. Eng.*, vol. 103, p. 108376, Oct. 2022, doi: 10.1016/J.COMPELECENG.2022.108376.
- [23] M. Padhyari, D. Saha, R. Kumar, L. N. Sethi, and A. Kumar, "Enhancing precision agriculture: A comprehensive review of machine learning and AI vision applications in all-terrain vehicle for farm automation," *Smart Agric. Technol.*, vol. 8, p. 100483, Aug. 2024, doi: 10.1016/j.atech.2024.100483.
- [24] A. Fath, N. Hanna, Y. Liu, S. Tanch, T. Xia, and D. Huston, "Indoor Infrastructure Maintenance Framework Using Networked Sensors, Robots, and Augmented Reality Human Interface..," *Futur. Internet*, vol. 16, no. 5, p. 170, May 2024, doi: 10.3390/FI16050170.
- [25] C. Mahulea, R. González, E. Montijano, and M. Silva, "Path planning of multirobot systems using Petri net models. Results and open problems.[Planificación de trayectorias en sistemas multirobot utilizando redes de Petri. Resultados y problemas abiertos]," *RIAI - Rev. Iberoam. Autom. e Inform. Ind.*, vol. 18, no. 1, pp. 19–31, Jan. 2021, doi: 10.4995/RIAI.2020.13785.
- [26] A. Gellert, D. Sarbu, S.-A. Precup, A. Matei, D. Circa, and C.-B. Zamfirescu, "Estimation of Missing LiDAR Data for Accurate AGV Localization," *IEEE Access*, vol. 10, pp. 68416–68428, 2022, doi: 10.1109/ACCESS.2022.3185763.
- [27] N. Kulaç and M. Engin, "Developing a Machine Learning Algorithm for Service Robots in Industrial Applications," *Machines*, vol. 11, no. 4, Apr. 2023, doi: 10.3390/MACHINES11040421.
- [28] S. Cebollada, L. Payá, A. Peidró, W. Mayol, and O. Reinoso, "Environment modeling and localization from datasets of omnidirectional scenes using machine learning techniques.," *Neural Comput. Appl.*, vol. 35, no. 22, pp. 16487–16508, Aug. 2023, doi: 10.1007/S00521-023-08515-Y.
- [29] P. Nourizadeh, F. J. S. McFadden, and W. N. Browne, "In situ skid estimation for mobile robots in outdoor environments," *J. F. Robot.*, vol. 41, no. 1, pp. 179–194, Jan. 2024, doi: 10.1002/ROB.22252.
- [30] H. S. Nasrallah *et al.*, "Elevating Mobile Robotics: Pioneering Applications of Artificial Intelligence and Machine Learning," *Rev. d'Intelligence Artif.*, vol. 38, no. 1, pp. 351–363, Feb. 2024, doi: 10.18280/RIA.380137.
- [31] M. Siami, T. Barszcz, and R. Zimroz, "Advanced Image Analytics for Mobile Robot-Based Condition Monitoring in Hazardous Environments: A Comprehensive Thermal Defect Processing Framework," *Sensors*, vol. 24, no. 11, Jun. 2024, doi: 10.3390/S24113421.
- [32] Y. Yan *et al.*, "The Navigation of Home Service Robot Based on Deep Learning and Machine Learning," *J. Robot.*, vol. 2024, p. 5928227, Jan. 2024, doi: 10.1155/2024/5928227.
- [33] T. Nowak, A. Große-Kreul, M. Boshoff, and B. Kuhlenkötter, "Enhancing Mobile Robot Position Estimation with Machine Learning Methods Using Camera-Based Tracking," *Procedia CIRP*, vol. 130, pp. 964–968, Jan. 2024, doi: 10.1016/J.PROCIR.2024.10.192.
- [34] S. Al Mahmud, A. Kamarulariffin, A. M. Ibrahim, and A. J. H. Mohideen, "Advancements and Challenges in Mobile Robot Navigation: A Comprehensive Review of Algorithms and Potential for Self-Learning Approaches," *J. Intell. Robot. Syst. Theory Appl.*, vol. 110, no. 3, Sep. 2024, doi: 10.1007/S10846-024-02149-5.
- [35] T. Aziz and K. Insoo, "Enhancing Indoor Localization Accuracy through Multiple Access Point Deployment," *Electron.*, vol. 13, no. 16, Aug. 2024, doi: 10.3390/ELECTRONICS13163307.
- [36] J. Fusic S *et al.*, "Momordica charantia leaf disease detection and treatment using agricultural mobile robot," *AIP Adv.*, vol. 14, no. 4, Apr. 2024, doi: 10.1063/5.0190928.
- [37] F. Burillo, M. P. Lambán, J. A. Royo, P. Morella, and J. C. Sánchez, "Real-Time Production Scheduling and Industrial Sonar and Their Application in Autonomous Mobile Robots," *Appl. Sci.*, vol. 14, no. 5, Mar. 2024, doi: 10.3390/APP14051890.
- [38] A. Gharbi, "A dynamic reward-enhanced Q-learning approach for efficient path planning and obstacle avoidance in mobile robotics," *Appl. Comput. Informatics*, 2024, doi: 10.1108/ACI-10-2023-0089.
- [39] A. Munaf and A. R. J. Almusawi, "Integration of Q-Learning and PID Controller for Mobile Robots Trajectory Tracking in Unknown Environments," *J. Eur. des Syst. Autom.*, vol. 57, no. 4, pp. 1023–1033, Aug. 2024, doi: 10.18280/JESA.570410.
- [40] M. Rybczak, N. Popowniak, and A. Lazarowska, "A Survey of Machine Learning Approaches for Mobile Robot Control," *Robotics*, vol. 13, no. 1, Jan. 2024, doi: 10.3390/ROBOTICS13010012.
- [41] R. Natarajan, S. R. P. S. C. Bose, H. L. Gururaj, F. Flammini, and S. Velmurugan, "Fault detection and state estimation in robotic automatic control using machine learning," *Array*, vol. 19, p. 100298, Sep. 2023, doi: 10.1016/J.ARRAY.2023.100298.
- [42] H. Li, H. Jiao, and Z. Yang, "AIS data-driven ship trajectory prediction modelling and analysis based on machine learning and deep learning methods," *Transp. Res. Part E Logist. Transp. Rev.*, vol. 175, 2023, doi: 10.1016/j.tre.2023.103152.
- [43] Y. Ou, Y. Cai, Y. Sun, and T. Qin, "Autonomous Navigation by Mobile Robot with Sensor Fusion Based on Deep Reinforcement Learning," *Sensors*, vol. 24, no. 12, Jun. 2024, doi: 10.3390/S24123895.
- [44] C. S. Tan, R. Mohd-Mokhtar, and M. R. Arshad, "A Comprehensive Review of Coverage Path Planning in Robotics Using Classical and Heuristic Algorithms," *IEEE Access*, vol. 9, pp. 119310–119342, Jan. 2021, doi: 10.1109/ACCESS.2021.3108177.
- [45] V. J. Hodge, R. Hawkins, and R. Alexander, "Deep reinforcement learning for drone navigation using sensor data," *Neural Comput. Appl.*, vol. 33, no. 6, pp. 2015–2033, Mar. 2021, doi: 10.1007/S00521-020-05097-X.
- [46] T. Zhang, Z. Su, J. Cheng, F. Xue, and S. Liu, "Machine vision-based testing action recognition method for robotic testing of mobile application," *Int. J. Distrib. Sens. Networks*, vol. 18, no. 8, Aug. 2022, doi: 10.1177/15501329221115375.
- [47] E. Erkan and M. A. Arserim, "Mobile Robot Application with Hierarchical Start Position DQN," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/4115767.
- [48] G. Castellano, P. De Marinis, and G. Vessio, "Weed mapping in multispectral drone imagery using lightweight vision transformers," *Neurocomputing*, vol. 562, p. 126914, Dec. 2023, doi: 10.1016/J.NEUROCOM.2023.126914.
- [49] T. Nakamura, M. Kobayashi, and N. Motoi, "Path Planning for Mobile Robot Considering Turnabouts on Narrow Road by Deep Q-Network," *IEEE Access*, vol. 11, pp. 19111–19121, 2023, doi: 10.1109/ACCESS.2023.3247730.
- [50] M. N. A. Ramadan, S. M. S. Hilles, and M. Alkhedher, "Design and Study of an AI-Supported Autonomous Stair Climbing Robot," *Elezzeri J. Sci. Eng.*, vol. 10, no. 3, pp. 571–585, Sep. 2023, doi: 10.31202/ECJSE.1272769.
- [51] R. Upadhyay, A. Asi, P. Nayak, N. Prasad, D. Mishra, and S. K. Pal, "Real-time deep learning-based image processing for pose estimation and object localization in autonomous robot applications," *Int. J. Adv. Manuf. Technol.*, vol. 127, no. 3–4, pp. 1905–1919, Jul. 2023, doi: 10.1007/S00170-022-09994-4.

- [52] Z. Zhou *et al.*, “A safe reinforcement learning approach for autonomous navigation of mobile robots in dynamic environments,” *CAAI Trans. Intell. Technol.*, 2023, doi: 10.1049/CIT2.12269.
- [53] C. Mavrogiannis, “Towards smooth mobile robot deployments in dynamic human environments,” *AI Mag.*, Sep. 2024, doi: 10.1002/AAAI.12192.
- [54] J. Shin, A. Hakobyan, M. Park, Y. Kim, G. Kim, and I. Yang, “Infusing Model Predictive Control Into Meta-Reinforcement Learning for Mobile Robots in Dynamic Environments,” *IEEE Robot. Autom. Lett.*, vol. 7, no. 4, pp. 10065–10072, Oct. 2022, doi: 10.1109/LRA.2022.3191234.
- [55] R. Akabane and Y. Kato, “Pedestrian Trajectory Prediction Based on Transfer Learning for Human-Following Mobile Robots,” *IEEE Access*, vol. 9, pp. 126172–126185, 2021, doi: 10.1109/ACCESS.2021.3111917.
- [56] H. Mohammadi Moghadam *et al.*, “Deep practice of internet of things image recognition technology based on deep learning in intelligent financial supervision system,” *Sensors*, vol. 23, no. 1, p. N.PAG, Nov. 2022, doi: 10.1007/s13369-024-09144-w.
- [57] D. T. Fasiolo, L. Scalera, E. Maset, and A. Gasparetto, “Towards autonomous mapping in agriculture: A review of supportive technologies for ground robotics,” *Rob. Auton. Syst.*, vol. 169, p. 104514, Nov. 2023, doi: 10.1016/J.ROBOT.2023.104514.
- [58] J. Choi and H. Lee, “Real-Time Traffic Light Recognition with Lightweight State Recognition and Ratio-Preserving Zero Padding,” *Electron.*, vol. 13, no. 3, Feb. 2024, doi: 10.3390/ELECTRONICS13030615.
- [59] R. H. Sun, X. Zhao, C. D. Wu, L. Zhang, and B. Zhao, “Research on Mobile Robot Navigation Method Based on Semantic Information,” *Sensors*, vol. 24, no. 13, Jul. 2024, doi: 10.3390/S24134341.
- [60] L. Li, L. Schulze, and K. Kalavadia, “Promising SLAM Methods for Automated Guided Vehicles and Autonomous Mobile Robots,” *Procedia Comput. Sci.*, vol. 232, pp. 2867–2874, Jan. 2024, doi: 10.1016/J.PROCS.2024.02.103.
- [61] V. Lacotte *et al.*, “Pesticide-Free Robotic Control of Aphids as Crop Pests,” *AgriEngineering*, vol. 4, no. 4, pp. 903–921, Dec. 2022, doi: 10.3390/AGRIENGINEERING4040058.
- [62] D. P. Brogan, N. M. DiFilippo, and M. K. Jouaneh, “Deep learning computer vision for robotic disassembly and servicing applications,” *Array*, vol. 12, p. 100094, Dec. 2021, doi: 10.1016/J.ARRAY.2021.100094.
- [63] J. Cui and G. Nie, “Motion Route Planning and Obstacle Avoidance Method for Mobile Robot Based on Deep Learning,” *J. Electr. Comput. Eng.*, vol. 2022, pp. 1–11, 2022, doi: 10.1155/2022/5739765.
- [64] H. Hao, “Researches Advanced in Visual Simultaneously Localization and Mapping based on Deep Learning,” *ACM Int. Conf. Proceeding Ser.*, pp. 1241–1246, Dec. 2022, doi: 10.1145/3584376.3584595.
- [65] K. Yeom, “Deep Reinforcement Learning Based Autonomous Driving with Collision Free for Mobile Robots,” *Int. J. Mech. Eng. Robot. Res.*, vol. 11, no. 5, pp. 338–344, May 2022, doi: 10.18178/ijmerr.11.5.338-344.
- [66] H. Liu and Y. Zhang, “ASL-DWA: An Improved A-Star Algorithm for Indoor Cleaning Robots,” *IEEE Access*, vol. 10, pp. 99498–99515, 2022, doi: 10.1109/ACCESS.2022.3206356.
- [67] E. Aguirre and M. García-Silvente, “Detecting and tracking using 2D laser range finders and deep learning,” *Neural Comput. Appl.*, vol. 35, no. 1, pp. 415–428, Jan. 2023, doi: 10.1007/S00521-022-07765-6.
- [68] C. H. Kim and D. Il Cho, “DNN-Based Slip Ratio Estimator for Lugged-Wheel Robot Localization in Rough Deformable Terrains,” *IEEE Access*, vol. 11, pp. 53468–53484, 2023, doi: 10.1109/ACCESS.2023.3280472.
- [69] C. Yang, J. Kang, and D. S. Eom, “Enhancing ToF Sensor Precision Using 3D Models and Simulation for Vision Inspection in Industrial Mobile Robots,” *Appl. Sci.*, vol. 14, no. 11, p. 4595, Jun. 2024, doi: 10.3390/app14114595.
- [70] H. Kabir, M.-L. Tham, and Y. C. Chang, “Internet of robotic things for mobile robots: Concepts, technologies, challenges, applications, and future directions,” *Digit. Commun. Networks*, vol. 9, no. 6, pp. 1265–1290, 2023, doi: <https://doi.org/10.1016/j.dcan.2023.05.006>.
- [71] N. Adiukou, N. P. Avdelidis, G. Tang, A. Plastopoulos, and S. Perinpanayagam, “CNN-fusion architecture with visual and thermographic images for object detection,” p. 29, Jun. 2023, doi: 10.1117/12.2665984.
- [72] J. Min, J. Pack, H. I. Park, and Y. Cha, “Classification of Floor Materials Using Piezoelectric Actuator-Sensor Pair and Deep Learning for Mobile Robots,” *IEEE Access*, vol. 12, pp. 28511–28519, 2024, doi: 10.1109/ACCESS.2024.3367435.
- [73] R. Chai, H. Niu, J. Carrasco, F. Arvin, H. Yin, and B. Lennox, “Design and Experimental Validation of Deep Reinforcement Learning-Based Fast Trajectory Planning and Control for Mobile Robot in Unknown Environment,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 35, no. 4, pp. 5778–5792, Apr. 2024, doi: 10.1109/TNNLS.2022.3209154.
- [74] H. Li, Y. Zhang, B. Ye, and H. Zhao, “A monocular vision positioning and tracking system based on deep neural network,” *J. Eng.*, vol. 2023, no. 3, Mar. 2023, doi: 10.1049/TJE2.12246.
- [75] G. Seeja, A. S. A. Doss, and V. B. Hency, “A Novel Approach for Disaster Victim Detection Under Debris Environments Using Decision Tree Algorithms With Deep Learning Features,” *IEEE Access*, vol. 11, pp. 54760–54772, 2023, doi: 10.1109/ACCESS.2023.3281461.
- [76] Y. Ye, X. Ma, X. Zhou, G. Bao, W. Wan, and S. Cai, “Dynamic and Real-Time Object Detection Based on Deep Learning for Home Service Robots,” *Sensors*, vol. 23, no. 23, p. 9482, Dec. 2023, doi: 10.3390/s23239482.
- [77] F. Stulp *et al.*, “Innovation Paths for Machine Learning in Robotics [Industry Activities],” *IEEE Robot. Autom. Mag.*, vol. 29, no. 4, pp. 141–144, Dec. 2022, doi: 10.1109/MRA.2022.3213205.
- [78] W. Chen *et al.*, “SLAM Overview: From Single Sensor to Heterogeneous Fusion,” *Remote Sens.*, vol. 14, no. 23, Dec. 2022, doi: 10.3390/RS14236033.
- [79] S. K. R. Moosavi, M. H. Zafar, and F. Sanfilippo, “Collaborative robots (cobots) for disaster risk resilience: a framework for swarm of snake robots in delivering first aid in emergency situations,” *Front. Robot. AI*, vol. 11, 2024, doi: 10.3389/FROBT.2024.1362294.
- [80] Q. Song, “Social entertainment robot based on artificial intelligence algorithm application in interactive mode of music classroom,” *Entertain. Comput.*, vol. 51, p. 100748, Sep. 2024, doi: 10.1016/J.JENTCOM.2024.100748.
- [81] H. Kabir, M. L. Tham, Y. C. Chang, C. O. Chow, and Y. Owada, “Mobility-Aware Resource Allocation in IoRT Network for Post-Disaster Communications with Parameterized Reinforcement Learning,” *Sensors*, vol. 23, no. 14, Jul. 2023, doi: 10.3390/S23146448.
- [82] N. K. Al-Shammari, H. B. Almansour, S. M. Basha, and S. T. Ahmed, “Tele-robotic recommendation framework using multi-dimensional medical datasets on COVID-19 classification,” *Int. J. Adv. Appl. Sci.*, vol. 9, no. 2, pp. 152–159, Feb. 2022, doi: 10.21833/IJAAS.2022.02.017.
- [83] Y. Li, T. Sha, T. Baker, X. Yu, Z. Shi, and S. Hu, “Adaptive vertical federated learning via feature map transferring in mobile edge computing,” *Computing*, vol. 106, no. 4, pp. 1081–1097, Apr. 2024, doi: 10.1007/S00607-022-01117-X.
- [84] K. Sivayazi and G. Mannayee, “Modeling and simulation of a double DQN algorithm for dynamic obstacle avoidance in autonomous vehicle navigation,” *e-Prime - Adv. Electr. Eng. Electron. Energy*, vol. 8, p. 100581, Jun. 2024, doi: 10.1016/J.PRIME.2024.100581.